

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET SPLIT

DIPLOMSKI RAD

**ANALIZA UTJECAJA BREXITA NA
BRITANSKO TRŽIŠTE KAPITALA PRIMJENOM
MODERNE TEORIJE PORTFELJA**

Mentor:

Izv. prof.sc. Branka Marasović

Student:

Frane Džaja, univ.bacc.oec.

Split, travanj 2017.

Sadržaj:

1. UVOD	4
1.1. Problem istraživanja	4
1.2. Predmet istraživanja	6
1.3. Hipoteze	7
1.4. Svrha i ciljevi istraživanja	8
1.5. Metode istraživanja	8
1.6. Doprinos istraživanja.....	9
1.7. Struktura diplomskog rada	10
2. MARKOWITZEV MODEL OPTIMIZACIJE PORTFELJA	11
2.1. Temeljne odrednice Markowitzeva modela	11
2.1.1. Prinos portfelja	13
2.1.2. Očekivana vrijednost prinosa portfelja.....	15
2.1.3. Varijanca prinosa portfelja	16
2.1.4. Funkcija korisnosti	18
2.2. Efikasna granica	21
2.3. Doprinosi i kritike moderne teorije portfelja.....	25
2.4. Rizičnost vrijednosti.....	27
2.5. Beta-mjera sistemskog rizika	31
3. BREXIT	35
3.1. Britansko tržište kapitala	35
3.1.1. Temeljne odrednice londonske burze	38
3.1.2. Indeksi londonske burze	40
3.2. Brexit i njegov utjecaj na britansko tržište kapitala	42
3.3. Brexit i njegov utjecaj na EU i svijet.....	46
4. FORMIRANJE PORTFELJA NA BRITANSKOM TRŽIŠTU KAPITALA.....	49
4.1. Dionice u sastavu portfelja	49
4.2. Izračun mjera rizika za promatrane dionice	50
4.3. Efikasna granica u razdoblju prije Brexita	52
4.4. Efikasna granica u razdoblju nakon Brexita.....	57
4.5. Usporedba dobivenih rezultata	62
ZAKLJUČAK	63
SAŽETAK.....	65

SUMMARY	66
LITERATURA:.....	67
POPIS SLIKA	70
POPIS TABLICA.....	71

1. UVOD

1.1. Problem istraživanja

Londonska burza stara je 300 godina te je jedna od najstarijih burzi¹. Najznačajnija je europska te jedna od najznačajnijih svjetskih burza koja pruža velike mogućnosti ulaganja i trgovanja, a ondje kotiraju dionice više od 2.900 kompanija iz više od 60 zemalja diljem svijeta. Kao takva predstavlja jednu od najstabilnijih burza na svijetu.

Tržišta kapitalasklona su čestim promjenama, te izloženasi sistemskom i nesistemskom riziku. Sistemski rizik naziva se još i tržišni, odnosno rizik kojeg nije moguće izbjeći u potpunosti bez obzira na stabilnost pojedinog tržišta. Nesistemski rizik za razliku od sistemskog je onaj na kojeg je moguće utjecati različitim kvalitetnim poslovnim odlukama.

2016. godina dokaz je da se i najstabilnija svjetska tržišta ne mogu oduprijeti utjecajima tržišnih rizika. Izlazak Velike Britanije iz Europske Unije na temelju referenduma doveo je do značajnih nestabilnosti ne samo britanskog tržišta kapitala, nego i svih svjetskih tržišta.

Odluka koja je donesena od strane većine stanovnika Velike Britanije srušila je vrijednost funte u odnosu na dolar na razinu na kojoj nije bila u zadnjih 30 godina, navedena odluka uništila je oko dvije milijarde eura u vrijednostima dionica, a kod nekih kompanija su gubici bili upravo drastični. Tako je promet dionicama Royal Bank of Scotland i banke Barclays na londonskoj burzi čak morao biti u jednom trenutku zaustavljen jer je gubitak premašio maksimalnu vrijednost².

Stručnjaci su predviđali katastrofalne ishode Brexita do te razine da se predviđala recesija. Brexit nije imao negativan utjecaj samo na Veliku Britaniju nego i na sva svjetska, ali primarno europska tržišta. Kako bi se što prije postigla željena stabilnost europske zemlje žele da proces izlaska Velike Britanije iz EU nastupi što prije.

Kako bi se utvrdio utjecaj koji je Brexit imao na britansko tržište kapitala te koje su posljedice s kojima se investitori moraju nositi u pogledu prinosa i rizika portfelja koristit će se moderna teorija portfelja.

¹<http://www.lseg.com/about-london-stock-exchange-group/history>

²<http://www.poslovnipuls.com/2016/06/28/post-brexite-neizvjesnost-neizdrziva-za-britansko-gospodarstvo-i-financije/>

Moderna teorija portfelja je jedna od najpoznatijih teorija pronalaženja optimalnog portfelja vrijednosnih papira čije temelje postavlja Harry Max Markowitz 1952. godine.

Osnovna Markowitzeva ideja bila je naći ravnotežu između rizika i prinosa što danas nazivamo Model prosjek-varijanca (MV model). Tim modelom možemo, uz pretpostavku da imamo sve potrebne informacije, formirati portfelj koji na određenom stupnju rizika donosi najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalni rizik³.

Kako je prethodno utvrđeno tržišta kapitala sklona su različitim promjenama i izložena su mnogim rizicima. Prema Markowitzevom modelu rizik koji nosi portfelj može se reducirati diversifikacijom. Diversifikacija portfelja odnosno formiranje portfelja kombinirajući vrijednosnice iz različitih sektora umanjit će vjerojatnost nastupa gubitka.

Na mogućnost diversifikacije portfelja utječu različite turbulencije na tržištu. Za vrijeme mirnih perioda na tržištu kapitala korelacija koja se javlja između vrijednosnica je mala što omogućava uspješnu diversifikaciju portfelja. S druge strane turbulentnost tržišta rezultirat će porastom korelacije između vrijednosnica te otežati diversifikaciju portfelja⁴.

Markowitzev model formira se na način da se postavi donja granica prinosa portfelja i tada se iz skupa mogućih portfelja izabere onaj koji ima minimalan rizik ili se postavi gornja granica prihvatljivog rizika te se tada izabere portfelj koji uz zadani rizik nosi najveći prinos⁵.

Markowitzev model koristit će se u radu kako bi se utvrdio odnos prinosa i rizika portfelja prije odluke Velike Britanije o napuštanju Europske Unije, te odnos prinosa i rizika nakon navedene odluke.

³Jerončić M., Aljinović Z. (2011): "Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija", Stručni članak, Ekonomski pregled 62 (9-10), str. 585

⁴Kunovac D. (2010): "Asimetrične korelacije na tržištu kapitala u Hrvatskoj", Odabrani prijevodi br.7/11, Institut za javne financije, str. 2

⁵ Tomić-Plazibat, N., Aljinović, Z., Marasović, B., 2006. Matematički modeli u financijskom upravljanju. Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 13

1.2. Predmet istraživanja

Predmet ovog istraživanja je korištenje Markowitzevog modela optimizacije portfelja u svrhu formiranja efikasne granice na britanskom tržištu kapitala u dva promatrana razdoblja. Razdoblju prije odluke britanskih stanovnika na nedavno održanom referendumu o napuštanju Europske Unije te razdoblju nakon što je navedena odluka donesena kako bi se pobliže objasnile različite posljedice koje je takva odluka imala ne samo na britansko tržište već i na sva svjetska tržišta.

Velika Britanija značajna je svjetska velesila te svaka velika promjena vezana za istu rezultira značajnim posljedicama za cijeli svijet. Objava odluke o Brexitu rezultirala je kaosom unutar minuta. Čak ako na prvi pogled ne postoji jasna veza pojedinih kompanija s Velikom Britanijom kao što je to na primjer slučaj s njemačkim BMW-om utjecaj Brexita postoji.

Uzbuna je nastala na burzama od Tokija pa do tržišta Južne Amerike, a naravno da su prije svega pogođene britanske i europske tvrtke. Također i dionice Deutsche Banka naglo gube vrijednost, a očito su počele spekulacije i protiv čitavog niza drugih europskih novčarskih institucija pa tako i protiv španjolskih i talijanskih banaka⁶.

Ovim istraživanjem želi se kroz primjer dvije efikasne granice formirane u dva različita razdoblja dokazati negativan utjecaj Brexita na britansko tržište. Također će se negativan utjecaj Brexita na dionice s britanskog tržišta dokazati računajući rizik dionica s londonske burze različitim mjerama rizika kao što su beta, varijanca i rizičnost vrijednosti (VaR), te teorijski prikazati posljedice s kojima se nose ostala svjetska tržišta.

⁶<http://www.poslovnipuls.com/2016/06/28/post-brexite-neizvjesnost-neizdrziva-za-britansko-gospodarstvo-i-financije/>

1.3 Hipoteze

Na temelju postavljenog problema i predmeta istraživanja definiraju se istraživačke hipoteze. Postavljene hipoteze će se kroz empirijski dio rada testirati s ciljem njihova prihvatanja ili odbacivanja.

Radne hipoteze:

H1- Prinos koji portfelj nosi investitoru uz zadanu stopu rizika značajno opada nakon Brexita.

Navedenom hipotezom istražiti će se utjecaj koji Brexit ima na prinos koji ostvaruje investitor na londonskoj burzi. Hipoteza će se istražiti izračunom efikasnih granica u razdoblju prije i poslije Brexita. Također koliki je utjecaj izlaska Velike Britanije iz EU na povećanje rizika s kojim se moraju nositi investitori na britanskom tržištu kapitala.

H2- Rizik dionica s londonske burze značajno raste nakon odluke o napuštanju Europske Unije od strane Velike Britanije.

Navedenom hipotezom istražiti će se porast rizika na britanskom tržištu kapitala nakon Brexita. Hipoteza će se prihvatiti ili odbaciti korištenjem mjera rizika poput bete, varijance te rizičnosti vrijednosti (VaR).

H3- Nestabilnost na britanskom tržištu kapitala negativno je utjecala na sva europska i svjetska tržišta.

Nestabilnost koja se javila na britanskom tržištu ima negativne konotacije na sva gospodarstva svijeta. Ovom hipotezom želi se istražiti koje su to posljedice s kojima se nose sva svjetska tržišta zbog utjecaja Brexita.

1.4 Svrha i ciljevi istraživanja

Nakon što su definirani problem i predmet istraživanja te definirane hipoteze utvrđuju se svrha i ciljevi istraživanja.

Osnovni cilj ovog istraživanja je utvrditi koje su posljedice nastupile na britanskom tržištu kapitala kao rezultat napuštanja Europske Unije od strane Velike Britanije. Cilj je utvrditi kako će se kretati odnos prinosa i rizika portfelja sastavljenog od dionica koje kotiraju na londonskoj burzi budući da su Brexitom nastupile različite nestabilnosti na tržištu. Svrha je ovog rada bolje razumijevanje pozicije investitora koji imaju značajna ulaganja na britanskom tržištu kapitala te načina na koji će se Brexit odraziti na prinos njihovih investicija.

Također cilj je proučiti kakav utjecaj Brexit ima na ostale europske i svjetske zemlje čije je poslovanje usko povezano s Velikom Britanijom, te stabilnost čijih tržišta značajno ovisi o stabilnosti britanskog tržišta kapitala budući da je riječ o jednoj od najznačajnijih ekonomija svijeta.

1.5 Metode istraživanja

Pri izradi teorijskog dijela rada, koji će se temeljiti na proučavanju raznovrsne literature, koristit će se sljedeće metode istraživanja poput: metode indukcije koja predstavlja vrstu posrednog zaključka kod kojeg se polazi od pojedinačnog ka općem, odnosno ono što vrijedi za svaki pojedinačni slučaj jedne vrste vrijedi za cijelu vrstu. Metoda dedukcije (donošenje zaključaka od pojedinačnih sudova na opće); metoda sinteze koja je jedna od osnovnih metoda spoznaje, a predstavlja spajanje jednostavnijih misli u složene, metoda analize odnosno postupak istraživanja i objašnjavanja putem raščlanjivanja složenih zaključaka na znatno jednostavnije dijelove, metoda dokazivanja i opovrgavanja tj. metoda koje se koristi kod dokazivanja točnosti postavljenih hipoteza, te komparativna metoda kojom će se pojedini pojmovi uspoređivati kako bi se utvrdile njihove sličnosti i razlike. Od matematičkih metoda koristiti će se metode matematičkog programiranja te matričnog računa.

U empirijskom dijelu rada koristit će se tablični kalkulator MS Excela pomoću kojeg će se formirati efikasni portfelji i izračunati VaR i beta, te analizirati utjecaj Brexita na britansko tržište kapitala.

1.6 Doprinos istraživanja

Harry Max Markowitz 1952. godine postavlja temelje moderne teorije portfelja. Do današnjeg dana moderna teorija portfelja bila je predmet istraživanja mnogih stručnjaka te su na temelju Markowitzevog modela napisani mnogi radovi koji su rezultirali boljim razumijevanjem ove tematike.

Moderna teorija portfelja predmet je i ovog rada, no u ovom slučaju koristit će se u svrhu boljeg razumijevanja aktualne teme koja se odnosi na izlazak Velike Britanije iz Europske Unije. Doprinos istraživanja odnosi se na utvrđivanje utjecaja koji je Brexit imao na britansko tržište kapitala. Analizirati će se utjecaj Brexita na odnos prinosa i rizika portfelja te nastavno na navedeno ukazati na posljedice s kojima se ne samo investitori nego i druge primarno europske zemlje moraju nositi zbog odluke britanskog naroda.

1.7 Struktura diplomskog rada

Rad zajedno s uvodom i zaključkom sadrži 5 poglavlja.

U uvodnom dijelu rada postavljaju se problem i predmet istraživanja, definiraju se istraživačke hipoteze koje će kasnije kroz istraživanje biti prihvaćene ili će se odbaciti. Također se postavljaju ciljevi istraživanja, metode istraživanja te doprinos koji će ovaj rad imati.

Markowitzev model optimizacije portfelja definiran je drugim poglavljem kroz koje će se utvrditi teorijske i matematičke odrednice Markowitzevog modela, te definirati način formiranja optimalnog portfelja. Također će se objasniti pojmovi VaR i beta.

Treće poglavlje odnosi se na upoznavanje čitatelja s britanskim tržištem kapitala i njegovim osnovnim odrednicama te detaljno obrađivanje Brexita u svrhu razumijevanja samog pojma te njegovih posljedica na britansko i ostala europska i svjetska tržišta.

Formiranje dioničkog portfelja u vremenskom razdoblju prije donošenja odluke o napuštanju EU od strane Velike Britanije, te formiranje portfelja nakon provođenja referenduma te usporedba navedenih portfelja u svrhu boljeg razumijevanja posljedica Brexita biti će prikazano u četvrtom poglavlju.

Na samom kraju rada donijet će se zaključak mogu li se na temelju cjelokupnog istraživanja prihvatiti ili odbaciti početno postavljene istraživačke hipoteze.

2. MARKOWITZEV MODEL OPTIMIZACIJE PORTFELJA

2.1. Temeljne odrednice Markowitzeva modela

Harry Max Markowitz je postavio temelje moderne teorije portfelja radom *Portfolio Selection* iz 1952. godine. Na objavljivanje rada čekalo se do 1959. godine kada je objavljen u ožujskom broju *Journal of Finance*. Markowitz je u svom radu predstavio model optimizacije portfelja, poznat kao i *MV model (mean-variance model)* koji se temelji na pronalasku ravnoteže, odnosno optimalnog odnosa između prinosa i rizika.

Dotadašnji pristup optimizaciji portfelja temeljio se na maksimizaciji očekivanog prihoda, što je vodilo vrlo rizičnom ulaganju ukupnih novčanih sredstava u dionicu s najvećim očekivanim prinosom. Markowitzev model je pored maksimizacije prihoda ukazao i na važnost rizika, te da cilj modernog upravljanja nije maksimizacija očekivanog prihoda nego optimiranje odnosa očekivanog prihoda i pripadnog rizika. Takav pristup optimizaciji portfelja u skladu je s maksimom „Nije dobro držati sva jaja u jednoj košari“⁷ koja racionalnim investitorima nudi rješenje kako „odabrati košare“, tj. koju kombinaciju vrijednosnih papira treba odabrati tako da se smanji rizik portfelja. Za svoja postignuća u razvoju moderne teorije portfelja Markowitz je 1990. godine dobio Nobelovu nagradu iz ekonomije.

Pretpostavka teorije je averzija investitora prema riziku, te odabir onog portfelja dionica koji donosi najveću moguću dobit uz najmanji mogući rizik. Racionalni investitor će između dvije vrijednosnice koje nose isti prinos odabrati onu koja nosi manji rizik gubitka. Ukoliko je investitor spreman preuzeti veći rizik, moguće je i ostvarivanje većih profita. Dakle, osnovna ideja Markowitzevog modela je formiranje optimalnog portfelja u kojem je jedan od ključnih faktora fiksiran. Tim modelom, uz pretpostavku da imamo sve potrebne informacije, moguće je formirati portfelj koji na određenom stupnju rizika donosi najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalni rizik.⁸

⁷maksima Burtona G. Malkiela, Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 1.

⁸Jerončić M., Aljinović Z., (2011): „Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija“, Stručni članak, Ekonomski pregled 62 (9-10), str. 585

Takav portfelj koji za zadanu stopu rizika ima najveću stopu prihoda, odnosno portfelj koji za zadanu stopu prihoda ima minimalni rizik Markowitz je nazvao *efikasnim portfeljom*.⁹

Kod formiranja portfelja, negativna korelacija između vrijednosnica je poželjnija od pozitivne korelacije vrijednosnica. U situacijama tržišne nestabilnosti, negativnom korelacijom bi se neutralizirali gubitci koje ostvaruje jedna vrijednosnica s prinosima druge vrijednosnice, dok bi pozitivna korelacija vrijednosnica u portfelju dovela do značajnih gubitaka za investitora zbog toga što se vrijednosnice kreću zajedno, što ujedno povećava i volatilnost portfelja. Financijsko tržište je neizvjesno, stoga je nužno izabrati onaj portfelj vrijednosnica koji će za investitora imati optimalan odnos prinosa i rizika.

Osnovne pretpostavke Markowitzevog modela¹⁰:

- prinosi na dionice su distribuirani po normalnoj distribuciji,
- investitori žele maksimizirati svoju ekonomsku korisnost,
- investitori su racionalni i imaju averziju prema riziku,
- investitori su dobro obaviješteni o svim relevantnim činjenicama potrebnima za donošenje investicijske odluke,
- nema transakcijskih i poreznih troškova,
- vrijednosnice su savršeno djeljive.

⁹Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split:Sveučilište u Splitu, Ekonomski fakultet Split, str. 137

¹⁰Jerončić M., Aljinović Z., (2011): „Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija“, Stručni članak, Ekonomski pregled 62 (9-10), str. 58

2.1.1. Prinos portfelja¹¹

Pretpostavlja se da investitor može ulagati u n različitih vrijednosnih papira u trenutku $t=0$ i da ih posjeduje sve do trenutka $t=T$ ¹². Pretpostavlja se također da nema transakcijskih troškova i da su vrijednosnice savršeno djeljive. Pretpostavka o beskonačnoj djeljivosti je puno bolje aproksimirana kod velikih portfelja institucionalnih investitora (fondova i sl.), nego kod malih portfelja pojedinačnih ulagača.

Cijene vrijednosnice u trenutku $t=0$ i trenutku $t=T$ određuju prinos i -te vrijednosnice R_i , $i \in \{1, 2, \dots, n\}$, u trenutku $t=T$. Preciznije, ako je u trenutku $t \in \{0, T\}$ cijena vrijednosnog papira $P_i(0)$, odnosno $P_i(T)$, tada se složeni kontinuirani prinos pojedinog vrijednosnog papira računa izrazom:

$$R_i = \ln \left(\frac{P_i(T)}{P_i(0)} \right) \quad (1)$$

a diskretni prinos izrazom:

$$R_i = \frac{[P_i(T) - P_i(0)]}{P_i(0)} \quad (2)$$

Ako je u promatranom vremenskom razdoblju isplaćena dividenda za promatranu dionicu, tada se ukupni prinos dionice računa tako da se brojnicima gornjih izraza doda isplaćena dividenda. Prinos izračunat kontinuiranim ukamaćivanjem uvijek je manji od prinosa izračunatog diskretnim ukamaćivanjem, ali razlika u rezultatu najčešće nije velika. Razlika u rezultatu prinosa izračunatog kontinuiranim ukamaćivanjem i diskretnim ukamaćivanjem nije toliko velika kada je riječ o dnevnim prinosima, a postaje izraženija za duža vremenska razdoblja. Složeni kontinuirani prinos je prikladnija mjera prinosa u odnosu na složeni diskretni prinos kada podatci o prinosima za periode iz prošlosti određuju distribuciju prinosa.

Nadalje oznaka π_i je dio početnog uloga x investiranog u vrijednosnicu i u trenutku $t=0$, to jest:

$$\pi_i = \frac{\psi_i P_i(0)}{x} \quad (3)$$

¹¹Bazirano na: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 2-7

¹² Ovaj model je jedno-periodični ili statički model (neovisan je o duljini trajanja vremenskog razdoblja)

Gdje je ψ_i broj i -tih vrijednosnica kupljenih u trenutku $t=0$. Vektor $\pi = (\pi_1, \dots, \pi_n)'$ nazvat ćemo vektorom portfelja investitora. Nadalje vrijedi:

$$\sum_{i=1}^n \pi_i = 1 \quad (4)$$

O izboru vektora portfelja π na početku promatranog razdoblja ovisit će ukupni prinos ili prinos portfelja u trenutku $t=T$:

$$R^n = \frac{x^n(T) - x}{x} \quad (5)$$

Gdje su $X^n(T) = \sum_{i=1}^n \psi_i P_i(T)$ ukupna novčana sredstva dobivena prodajom dionica u trenutku $t=T$.

U diskretnom slučaju prinosa portfelja vrijedi:

$$R^n = \sum_{i=1}^n \pi_i R_i.$$

Važno je napomenuti da ponekad udjeli $\pi_i \in \{1, 2, \dots, n\}$ mogu poprimiti i negativne vrijednosti što je u praksi poznato pod pojmom kratke prodaje (*short sale*). Mnogi investitori se nadaju da će uspjeti kupiti dionicu po manjoj cijeni i prodat je po većoj i da će oni zaraditi na prodaji dionice u budućnosti. Kratka prodaja predstavlja jednu vrstu trgovine na financijskom tržištu koja se može opisati izrekom „Prodaj skupo, kupi jeftino,“ kod koje je proces prodaje obrnut. Investitor prvo prodaje vrijednosnicu koja nije u njegovom fizičkom vlasništvu tj. posudi je vrijednosnicu od treće osobe (npr. brokera) i proda je, nadajući se kasnijoj kupnji po manjoj cijeni. Stvarni vlasnik tog vrijednosnog papira mora dati dozvolu za njegovu kratku prodaju i ima pravo u svakom trenutku znati kada se dogodila transakcija kratke prodaje i tko je posudio njegov vrijednosni papir. Također, stvarni vlasnik ostvaruje dividendu od dionice koju mu investitor mora isplatiti u jednakom iznosu kao što je to činila i kompanija da ne bi bio oštećen u transakciji kratke prodaje. Ako su investitorski troškovi na kraju transakcije, od kupnje vrijednosnog papira i isplaćene dividende, manji od cijene po kojoj je na početku prodao vrijednosni papir, investitor će ostvariti pozitivan prinos.

2.1.2. Očekivana vrijednost prinosa portfelja¹³

Budući da je cijena vrijednosnice $P_i(t)$ u nekom budućem trenutku t slučajna varijabla i prinos $R_i(t)$ iste vrijednosnice i u trenutku t je slučajna varijabla.

Promatranjem vrijednosti prinosa u razdobljima iz prošlosti može se uočiti da imaju određenu distribuciju. Postavlja se pitanje kakvog će oblika biti funkcija distribucije prinosa portfelja ako su poznate funkcije distribucije prinosa pojedinačnih vrijednosnih papira?

Pretpostavka da su distribucije prinosa portfelja i distribucije prinosa individualnih ulaganja približno normalne predvidio je i Markowitz u svojim istraživanjima. Normalna distribucija se može kompletno okarakterizirati poznajući njena dva pokazatelja: aritmetičku sredinu i standardnu devijaciju. Osnovu za izračunavanje vjerojatnosti određenog rezultata u nizu predstavlja normalna distribucija. Stoga je cilj pronalaženje povezanosti aritmetičke sredine i standardne devijacije prinosa portfelja s odgovarajućim parametrima distribucije prinosa pojedinačnih vrijednosnih papira koji čine portfelj.

Očekivana vrijednost zbroja dviju slučajnih varijabli jednaka je zbroju očekivanih vrijednosti pojedine slučajne varijable, tj. da vrijedi $E(X+Y)=E(X)+E(Y)$ i da je očekivana vrijednost umnoška konstante i slučajne varijable jednaka umnošku konstante i očekivane vrijednosti slučajne varijable, tj. $E(\alpha X)=\alpha E(X)$ te dobivamo izraz za očekivani prinos portfelja:

$$\mu_\pi = E(R_\pi) = E(\sum_{i=1}^n \pi_i R_i) = \sum_{i=1}^n \pi_i E(R_i) = \sum_{i=1}^n \pi_i \mu_i \quad (6)$$

¹³Bazirano na: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 7

Zaključak je da aritmetička sredina ili očekivana vrijednost prinosa portfelja koji se sastoji od n vrijednosnica je vagana aritmetička sredina prinosa individualnih ulaganja, gdje su ponderi udjeli individualnih vrijednosnica u portfelju definirani relacijom (3).

2.1.3. Varijanca prinosa portfelja¹⁴

Rizik je uz prinos osnovni parametar kod izbora portfelja. Pod pojmom rizika podrazumijeva se odstupanje rezultata u budućnosti od očekivanih i planiranih rezultata. Što je veća veličina i vjerojatnost tog odstupanja veći je i rizik. Pod financijskim rizikom podrazumijeva se da pri ulaganju u pojedini vrijednosni papir postoji vjerojatnost da investirana sredstva prinesu manju dobit od očekivane ili čak ostvare gubitak. Odstupanja vrijednosti od njezine očekivane srednje vrijednosti mogu se mjeriti varijancom i standardnom devijacijom.¹⁵

Markowitz rizik ulaganja u pojedinu vrijednosnicu kvantificira varijancom prinosa $Var(R_i)$. Kao što je već navedeno, normalna distribucija prinosa dionica je jedna od pretpostavki Markowitzevoga modela. Uz tu pretpostavku dionice čija vrijednost više varira u odnosu na očekivanu vrijednost su rizičnije vrijednosnice, stoga varijanca predstavlja prikladnu mjeru rizika.

U situaciji kada je varijanca $Var(R_i)=0$ možemo reći da je vrijednosnica bezrizična, u protivnom je vrijednosnica rizična.

Rizik portfelja definiramo kao varijancu prinosa portfelja $Var(R^\pi)$ koja je definirana izrazom:

$$Var(R^\pi) = E\{[(R^\pi)^2] - [E(R^\pi)]^2\} \quad (7)$$

¹⁴Bazirano na: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 8-10.

¹⁵Živković S (2005) : „Formiranje optimalnog portfelja hrvatskih dionica i mjerenje tržišnog rizika primjenom Var metode“, magistarski rad, Sveučilište u Ljubljani, Ekonomski fakultet Ljubljana, str. 7.

Korištenjem linearnosti matematičkog očekivanja, može se pokazati da je :

$$Var(R^\pi) = E[(R^\pi)^2] - [E(R^\pi)]^2 \quad (8)$$

Raščlanjivanjem ovog izraza i primjenom navedenih svojstava aditivnosti i multiplikativnosti očekivane vrijednosti slučajne varijable, dobiva se:

$$Var(R^\pi) = \sum_{i=1}^n \sum_{j=1}^n \pi_i \sigma_{ij} \pi_j \quad (9)$$

gdje je :

$Var(R^n)$ - rizik portfelja

π_i - vrijednosni udio i -te vrijednosnice u portfelju;

π_j - vrijednosni udio j -te vrijednosnice u portfelju;

σ_{ij} - kovarijanca vrijednosnica i i j

$$\sigma_{ij} = Cov(R_i, R_j) = E(R_i, R_j) - E(R_i)E(R_j), i, j \in \{1, 2, \dots, n\}$$

Kovarijanca prinosa vrijednosnice same sa sobom $\sigma_{i,i}$ može se tretirati kao varijanca prinosa promatrane vrijednosnice:

$$Var(R_i) = E[(R_i)^2] - [E(R_i)]^2 = (R_i R_i) - E(R_i)E(R_i) = Cov(R_i, R_i) \quad (10)$$

Budući da je

$$\sum_{i=1}^n \sum_{j=1}^n \pi_i \pi_j = 1 \quad (11)$$

Možemo reći da jednakost (9) izražava $Var(R^n)$ kao vagani prosjek n^2 varijanci i kovarijanci prinosa vrijednosnica u portfelju.

Za razliku od očekivane vrijednosti prinosa portfelja koja je linearna funkcija udjela investicija u portfelju, varijanca prinosa portfelja nije linearna funkcija udjela investicija. Razlog tome je što se moguće varijance prinosa oko očekivanih vrijednosti svake investicije ne moraju poklapati niti intezitetom niti smjerom kretanja. Zbog toga će varijanca prinosa portfelja ovisiti o udjelima pojedinih vrijednosnica u portfelju, varijancama prinosa navedenih vrijednosnica te korelaciji između prinosa tih vrijednosnica u portfelju.

2.1.4. Funkcija korisnosti¹⁶

Korisnost je subjektivna vrijednost za svakog pojedinca. Vrijednost stvari nije određena cijenom koju netko želi platiti za nju, već korisnošću koja ona ima za vlasnika. Klasični primjer korisnosti bila bi čaša vode koja ima puno veću korisnost za nekoga tko se izgubio u pustinji, nego za nekog u civilizaciji. Cijena vode može biti jednaka u oba slučaja, ali osobe u različitim situacijama mogu različito percipirati njenu vrijednost, odnosno nešto što za jednog pojedinca ima veliku korisnost za drugog pojedinca nema značajnu korisnost.

Funkcija korisnosti određuje ponašanje investitora. Svi investitori imaju averziju prema nepotrebnom riziku i preferiraju sigurnost, te se s obzirom na preferenciju rizika razlikuju tri osnovna oblika funkcije korisnosti:

- Konkavna funkcija korisnosti; karakteristična za osobe koje izbjegavaju rizik (risk averse)
- Konveksna funkcija korisnosti; karakteristična za osobe koje su sklone riziku (riskseekers)
- Linearna funkcija korisnosti; karakteristična za osobe koje su indiferentne u odnosu na rizik tj. rukovode se jedino maksimalnim očekivanim povratom (riskneutral)

¹⁶Bazirano na: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 9-13.

Moderna portfolio teorija pretpostavlja da investitori imaju konkavnu funkciju korisnosti tj. da su risk averse. Takav će investitor između dvije vrijednosnice s istom stopom povrata uvijek izabrati onu sa manjim rizikom.¹⁷

Funkcija korisnosti $U(W)$ je rastući oblik te funkcije što znači da će investitor u svakom slučaju preferirati mogućnost u kojoj može ostvariti veći prinos u usporedbi s mogućnošću u kojoj će ostvariti manji prinos uz pretpostavku da su opcije jednako vjerojatne.


Oblik funkcije korisnosti odražava stav ulagača prema riziku. Osobe koje izbjegavaju rizik (risk-averse person) neće preuzeti rizik i investirati svoja sredstva u situaciji kada je vjerojatnost dobitka i gubitka jednaka odnosno 50:50, što možemo zapisati ovako:

$$U(W) > \frac{1}{2} U(W+G) + \frac{1}{2} U(W-G) \quad (12)$$

Pomnožimo li prethodni izraz s 2, dobivamo:

$$U(W) - U(W-G) > U(W+G) - U(W) \quad (13)$$

Ovakva funkcija korisnosti je konkavna $U''(W) < 0$. Investitor koji izbjegava rizik smanjuje novčani udio svoje imovine investirane u rizični portfelj usporedno s povećanjem svojeg bogatstva i izgleda na sljedeći način:



Slika 1. Funkcija korisnosti investitora koji izbjegava rizik

Izvor: Tomić-PlazibatN., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str.11.

¹⁷Živković S (2005) : „Formiranje optimalnog portfelja hrvatskih dionica i mjerenje tržišnog rizika primjenom Var metode“, magistarski rad, Sveučilište u Ljubljani, Ekonomski fakultet Ljubljana, str. 17.

Osoba koja indiferentna na rizik (risk-neutral person) svejedno je hoće li investirati dio bogatstva ili ne u situaciji kada je vjerojatnost dobitka i gubitka jednaka odnosno 50:50, te za takvog investitora vrijedi:

$$U(W) = \frac{1}{2}U(W+G) + \frac{1}{2}U(W-G) \quad (14)$$

tj.

$$U(W) - U(W-G) = U(W+G) - U(W) \quad (15)$$

U ovom slučaju funkcija korisnosti je linearna, tj. $U''(W)=0$.


Za osobe sklone riziku (risk-seeking person) vrijedi relacija:

$$U(W) < \frac{1}{2}U(W+G) + \frac{1}{2}U(W-G) \quad (16)$$

odnosno:

$$U(W) - U(W-G) < U(W+G) - U(W) \quad (17)$$

te je riječ o konveksnoj funkciji korisnosti, za koju vrijedi $U''(W)>0$. Ovaj investitor će povećati novčani udio svoje imovine investirane u rizični portfelj usporedno s povećanjem svoga bogatstva.



Slika 2. Funkcija korisnosti investitora koji izbjegava rizik, investitora koje je indiferentan u odnosu na rizik i investitora koji je sklon riziku

Izvor: Tomić-PlazibatN., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 12.

Funkciju korisnosti investitora koji ulaže na tržište kapitala možemo prikazati kao funkciju očekivanog prinosa portfelja. očekivana vrijednost funkcije korisnosti tada ovisi o očekivanom prinosu portfelja i varijanci:

$$E(U)=E(U)(\mu_{\pi}, \sigma_{\pi}^2) \quad (18).$$

Kao što je već navedeno pretpostavka Markowitza jest da je funkcija korisnosti konkavna, odnosno da postoji određeni stupanj averzije prema riziku i da je kvadratna funkcija.

2.2. Efikasna granica


Prema Markowitzu, svaki portfelj je okarakteriziran svojim prinosom (očekivanim prinosom) i svojim rizikom (varijancom prinosa). Skup mogućih portfelja čine svi portfelji koji se mogu sastaviti od N zadanih rizičnih vrijednosnica.¹⁸ Pri izboru optimalnog portfelja investitoru je najvažnije postići što veći prinos. Ukoliko je to jedini kriterij, investitor će sav svoj iznos

¹⁸Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 139.

uložiti u vrijednosnicu s najvećim očekivanim prinosom, koja je često vrlo rizična vrijednosnica. Markowitzeva osnovna ideja optimizacije portfelja je pronaći ravnotežu između rizika (tj. varijance prinosa portfelja) i prinosa portfelja.

Markowitzev model optimizacije portfelja formira se na način da ulagač zada donju granicu prinosa portfelja i tada se iz skupa mogućih portfelja izabere onaj koji ima minimalnu varijancu, odnosno minimalan rizik. Drugi pristup je da ulagač zada gornju granicu prihvatljivog rizika i onda se iz mogućeg skupa portfelja izabere onaj koji maksimizira prinos.¹⁹ Takav portfelj koji za zadanu stopu rizika ima najveću stopu prihoda, odnosno portfelj koji za zadanu stopu prihoda ima minimalan rizik, Markowitz je nazvao efikasnim portfeljom.²⁰

Portfelj se može prikazati točkom u koordinatnoj ravnini gdje apscisa predstavlja rizik, a ordinata stupanj očekivane stope prinosa.



Slika 3. Skup mogućih portfelja


Izvor: Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 139

¹⁹ Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 13.

²⁰ Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 137

Lijeva granica skupa mogućih portfelja naziva se skup minimalne varijance (minimum-variance set). Njega sačinjavaju točke koje za danu stopu prinosa imaju najmanju varijancu.

Dio skupa minimalne varijance koji prikazuje portfelje koji za zadanu standardnu devijaciju imaju maksimalan prinos naziva se efikasnom granicom (efficient frontier).²¹ Navedeno je prikazano na slici 4.



Slika 4. (a) skup minimalne varijance (b) efikasna granica

Izvor: Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 139

Promatrajući sve moguće portfelje određenog skupa vrijednosnica, investitora će zanimati oni portfelji koji leže na krivulji minimalne varijance. Takvi portfelji za određeni prinos imaju najmanju varijancu. Ako portfelji za zadanu stopu rizika imaju maksimalan prinos, oni leže na efikasnoj granici i zovu se efikasnim portfeljima.

Za portfelj se može reći da je efikasan samo ako ne postoji drugi portfelj koji ima:²²

- veću očekivanu stopu povrata i manju standardnu devijaciju
- veću očekivanu stopu povrata i istu standardnu devijaciju ili
- istu očekivanu stopu povrata i manju standardnu devijaciju

²¹Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 139

²²Živković S (2005) : „Formiranje optimalnog portfelja hrvatskih dionica i mjerenje tržišnog rizika primjenom Var metode“, magistarski rad, Sveučilište u Ljubljani, Ekonomski fakultet Ljubljana str 19.

Matematički, efikasní portfelj možemo definirati kao:


$$\max E(R_\pi) = \pi' E(R) = \sum_{i=1}^N \pi_i E(R_i) \quad (19).$$

Uz ograničenja:

$$\pi' S \pi = c \quad (20)$$

$$\sum_{i=1}^N \pi_i = 1 \quad (21)$$

U sljedećem primjeru je prikazano kako portfelj *C* nije efikasan naspram portfelja *A* koji ima veći očekivani prinos, a manji rizik. U tom slučaju se može reći da portfelj *A* dominira nad portfeljem *C* i portfelj *B* dominira nad portfeljem *C* budući da se i portfelj *B* nalazi na efikasnoj granici te ima maksimali prinos uz zadanu stopu rizika.



Slika 5. Primjer efikasnog i neefikasnog portfelja

Izvor: Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 141.

U ovom modelu udjeli pojedinih dionica u portfelju π_i su nepoznate varijable $i \in \{1, 2, \dots, N\}$. Navedeno dovodi do pitanja: koliki udio pojedine dionice u portfelju mora biti da bi prinos portfelja bio maksimalan, uz zadani rizik (konstanta c). Također je važno napomenuti da udjeli π_i , $i \in \{1, 2, \dots, N\}$ ponekad mogu poprimiti i negativne vrijednosti, što je poznato pod pojmom kratke prodaje.


2.3. Doprinosi i kritike moderne teorije portfelja

Markowitzeva moderna teorija portfelja predstavlja najznačajniju inovaciju 20. stoljeća na području investiranja i upravljanja portfolijem vrijednosnih papira.²³ Doprinos Markowitzeve teorije portfelja leži u činjenici da sve do 1952. godine nije postojao odgovor na pitanje: *kako izabrati dionice koje će sačinjavati portfelj?*²⁴ Koncept moderne teorije portfelja je teorijski jednostavan i empirijski dokazan kao pouzdan u normalnim tržišnim uvjetima. Moderna teorija portfelja je omogućila da se u svrhu formiranja optimalnog portfolija, pored očekivanog prinosa i rizika pojedine vrijednosnice uzme i treći element, međusobna koreliranost vrijednosnica unutar portfelja. Markowitz je pokazao da se diverzifikacijom, odnosno povećanjem broja dionica u portfelju smanjuje rizik portfelja, što investitorima omogućuje kreiranje portfelja koji su istovremeno profitabilniji i nose manji rizik.

Diverzifikacijom portfelja se ne može postići potpuna eliminacija rizika. Ukupni rizik se sastoji od dvije osnovne komponente, a to su: sistemski i nesistemski rizik. Sistemski rizik je opći dio rizika koji se ne može otkloniti kombiniranjem investicija u portfelju tj. diverzifikacijom. Nesistemski rizik je onaj dio rizika koji se može otkloniti diverzifikacijom portfelja. Kao što se vidi na slici 6. diverzifikacija može smanjiti rizik ulaganja do razine sistemskog rizika u idealnom scenariju.

²³Živković S., (2005): „Formiranje optimalnog portfolia hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode“, Ekonomski fakultet, Ljubljana, str.21

²⁴ Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 27



Slika 6. Sistemski i nesistemski rizik u odnosu na ukupni rizik

Izvor: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 29.

Kritike Markowitzevog modela se javljaju zbog pretpostavki:

- Funkcija korisnosti koja prezentira preferencije investitora je kvadratna funkcija
- prinosi su normalno distribuirani.

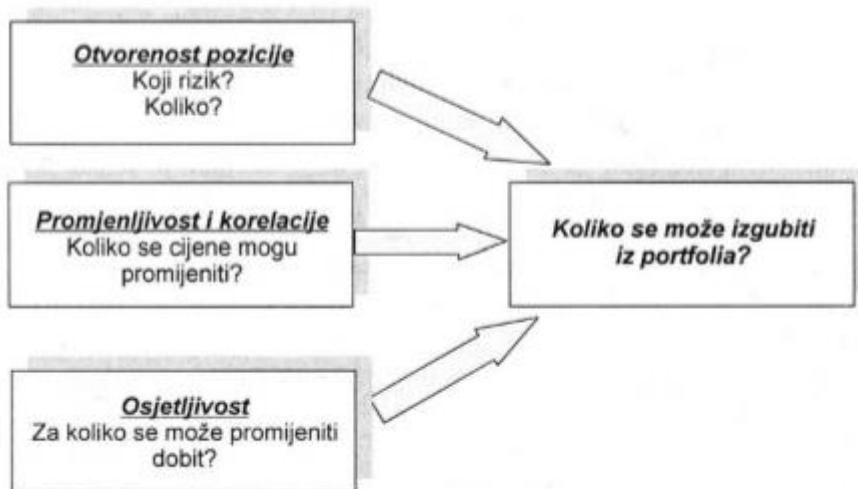
Na temelju navedenih pretpostavki javljaju se kritike ovog modela. Normalna distribucija prinosa nikad nije dokazana te je većina empirijskih testova na tržištima kapitala imala za rezultat asimetričnu i (ili) šiljastu distribuciju.

Sljedeći razlog kritike je potreba za izračunavanjem velikog broja standardnih devijacija i korelacija prinosa vrijednosnih papira koji su uzeti u analizu. Potonja kritika je bila više kritizirana u vrijeme nastanka Markowitzevog modela zbog obujma i složenosti izračuna velikog broja parametara. No, zahvaljujući razvoju računala i softvera problem optimizacije portfelja može se riješiti brzo i efikasno primjenom Markowitzevog modela²⁵.

²⁵Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 26

2.4 Rizičnost vrijednosti

Rizičnost vrijednosti (Value at Risk ili VaR) je statistička mjera koja procjenjuje budući rizik neke imovine ili cijelog portfelja i nastoji cijeli rizik portfelja svesti na jednu brojku. Definira se kao najgori predviđeni gubitak (najveći iznos novca koji može biti izgubljen) u određenom vremenskom razdoblju uz određenu razinu pouzdanosti²⁶. Metoda rizične vrijednosti se može prikazati kao slika 7.



Slika 7. Metoda rizične vrijednosti

Izvor: Šverko I. (2002): „Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima u financijskim institucijama“, Ekonomski pregled, Vol. 53 No.7-8, 2002., str. 644

Rizična vrijednost, dakle, uzima u obzir otvorenost pozicije, promjenljivost, koeficijente korelacije i osjetljivosti svake pojedine stavke portfelja. Ta se metoda može primijeniti na mnoge aktivne instrumente, kao što su vlasničke i dužničke vrijednosnice, devize, derivati i slično.²⁷

²⁶Aljinović Z., Marasović B.: „Rizičnost vrijednosti“, nastavni materijali, Ekonomski fakultet u Splitu

²⁷Šverko I.(2002): „Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima u financijskim institucijama“, Ekonomski pregled, Vol. 53 No.7-8., str. 644

Događaj koji je prethodio razvoju i popularizaciji VaR-a (kao metode upravljanja rizikom) je slom burze iz 1987. godine. dotadašnji statistički modeli nisu nagovještavali slom, što je poljuljalo povjerenje u kvantitativne metode. Procjena rizika metodom rizičnosti vrijednosti potječe iz američke banke *JP Morgan*, kada je njen tadašnji čelnik Denis Weatherstone zadao svojim analitičarima da mu do kraja radnog dana izračunaju koliko njihova kompanija može izgubiti zbog potencijalnih sutrašnjih promjena na tržištu, te da podnesu izvještaj u kojemu će stajati samo jedan broj. Od tada *JP Morgan* svakodnevno objavljuje podatke o cjenovnim kretanjima i koeficijentima korelacije instrumenata za četiri tržišta u 30 zemalja svijeta.

Dva osnovna parametra koja definiraju VaR i koja su nužna za njegov izračun su:


- Razina pouzdanosti α
- Vremensko razdoblje t

Razina pouzdanosti se uglavnom kreće između 90% i 99%. Neke kompanije koriste i po nekoliko različitih razina pouzdanosti (npr. 95% i 99%). Osnovni koncept VaR čini ga različitim od ostalih tehnika za mjerenje rizika. Naime, VaR model pokazuje „koliko je vjerojatno“ da ćemo izgubiti, dok ostale tehnike govore „koliko možemo izgubiti“. Također, jedna veoma bitna stvar za VaR metodu koja nije spomenuta u definiciji je ta da VaR uzima u obzir efekte diverzifikacije koja postoji u portfelju.

Vremensko razdoblje koje se koristi u VaR analizi aktivnih financijskih institucija (banaka i raznih fondova) je jedan dan. Za banke i nema smisla uzimati u obzir neko dulje razdoblje jer se tržište pozicije i odnosi mijenjaju dinamički iz dana u dan. S druge strane, investicijski menadžeri koriste razdoblje od jednog mjeseca, dok korporacije mogu koristiti kvartalne ili čak godišnje projekcije rizika.²⁸

²⁸Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 160

Razvojem VaR sustava mjerenja rizika razvila su se tri glavna načina mjerenja:



Slika 8. Metode izračuna rizične vrijednosti

Izvor: Šverko I. (2001): „Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj“, Financijska teorija i praksa, Vol. 25 No. 4, str. 606

- RiskMetrics model - poznat je u praksi pod drugim nazivima kao: parametarski model, delta normalan model, model varijance i kovarijance i linearni model. Izračun VaR-a parametarskom metodom vrši se na način da se pretpostavi da distribucija povrata odgovara nekoj od teorijskih distribucija, kao što je npr. normalna distribucija. Primjenom ove pretpostavke, VaR za tržišni rizik izračunava se na temelju dva osnovna parametra: srednje vrijednosti dobitaka/gubitaka (ili stope povrata) promatranog portfolija, te standardne devijacije promatranih podataka. Iako za parametrijski pristup određivanja VaR-a nije potrebna pretpostavka da su dobitci/gubici portfolija normalno raspodjeljeni najčešće se pri ovom načinu koristi upravo normalna distribucija ili približna alternativa (eliptična distribucija).²⁹
- Povijesna metoda - najjednostavnija i najrasprostranjenija metoda za izračun rizične vrijednosti koja prema mnogim istraživanjima daje zadovoljavajuće rezultate. Povijesna simulacija spada u skupinu neparametrijskih metoda procjena VaR-a bez postavljanja pretpostavki o distribuciji povrata. Temelji se na pretpostavci da će kretanje prinosa u budućnosti biti slično kretanjima prinosa u prošlosti te se na osnovu toga može procijeniti rizik. Ne zasniva se na koeficijentima korelacije među dijelovima portfelja. Tom se metodom ocjenjuju tržišna vrijednost portfelja s obzirom na tržišne cijene dijelova portfolija n posljednjih dana. Osnovna ideja tog koncepta je uzimanje u obzir trenutnog portfolija te ponovna ocjena njegove tržišne vrijednosti na osnovi tržišnih cijena iz prethodnih dana (od jučer, prekjučer itd.). Na osnovi cijena

²⁹ Živković S., (2005):“ Formiranje optimalnog portfolia hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode“, Ekonomski fakultet, Ljubljana, str.64

iz prošlosti određuje se „pretpostavljena“ tržišna vrijednost trenutnog portfolija u n posljednjih dana. Nakon toga se tako dobivene tržišne vrijednosti poredaju od onih koje daju najveće gubitke do onih koji donose najveće dobitke, te se tako dolazi do rizične vrijednosti ili najvećeg očekivanog gubitka promatranog portfolija.³⁰

- Monte Carlo simulacija - osnovna pretpostavka RiscMetrics modela jest da se dobici ili gubici iz portfolija distribuiraju normalnom krivuljom. Pretpostavi li se da takva postavka nije realna, može se razviti povijesni model koji se zasniva na povijesnim podacima, tj. na premisi da će se buduće promjene kretati baš kao i u prošlosti. Međutim, ako se pretpostavi da ni to predviđanje nije dovoljno realno, uvodi se Monte Carlo simulacija, sa zadatkom statičkog generiranja slučajnih scenarija na osnovi kojih će se odrediti rizična vrijednost. Monte Carlo simulacija je najkompleksiniji, ali i najtočniji model izračuna rizične vrijednosti.³¹ Monte Carlo simulacije pokrivaju širok spektar matematičkih modela i algoritama i u potpunosti uzimaju u obzir njihove međusobne korelacije. Korištenjem Monte Carlo simulacije pri izračunu VaR-a nasumično se stvaraju mnogobrojni scenariji za buduća kretanja tržišnih varijabli, a nelinearnim vrednovanjem se za svaki scenarij izračunavaju vrijednosti promjena. Vrijednost VaR-a se izračunava uzimanjem najvećeg gubitka uz određenu razinu vjerojatnosti.³²

Iako se ova tri pristupa izračuna VaR-a razlikuju i često daju različite rezultate, pored toga imaju neka zajednička ograničenja i karakteristike. Svaki pristup koristi faktore rizika kao što su kamatna stopa, intervalutni tečajevi, volatilnost itd. Navedeni pristupi koriste povijesnu distribuciju promjena cijena na tržištu kako bi odredili odgovarajuću distribuciju za dobivene podatke. Takav pristup predstavlja problem izbora vremenskog horizonta iz kojeg će koristiti povijesne podatke zbog nemogućnosti istovremenog zadovoljavanja dva ekstrema kojima se teži. S jedne strane, želi se uzeti dovoljno dugo povijesno razdoblje u kojem bi dobiveni podaci u sebi sadržavali rijetke i ekstremne događaje, koji su najčešće i uzrok velikih gubitaka. S druge strane, potrebno je koristiti najnovije tržišne podatke koji ocrtavaju

³⁰Šverko I. (2001): „Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj“, Financijska teorija i praksa, Vol. 25 No. 4, str. 608

³¹Šverko I. (2001): „Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj“, Financijska teorija i praksa, Vol. 25 No. 4, str. 610

³²Živković S., (2005): „Formiranje optimalnog portfolia hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode“, Ekonomski fakultet, Ljubljana, str.69

najnovija kretanja na tržištima, budući da se VaR-om želi predvidjeti buduća distribucija povrata.

Jedinica mjere VaR-a je osnovna valuta kojom se tvrtka koristi pri izradi svojih izvještaja.

U usporedbi s konvencionalnim mjerama rizika, rizičnost vrijednosti omogućuje kontrolu rizika različitih vrsta imovine kao što su: strana valuta, dionice, obveznice, roba, te kontrolu rizika kamatnih stopa i kreditnog rizika.

2.5. Beta-mjera sistemskog rizika

Beta je mjera rizika vrijednosnice koja se drži u dobro diverzificiranom portfelju. Investitori drže, u pravilu, tržišni portfelj ili veliki, diverzificirani portfelj. Pod velikim portfeljom podrazumijeva se portfelj u kojem investitor neograničeno povećava broj vrijednosnica, pa je sav nesustavni rizik eliminiran. Po nekim se teorijama smatra da je dobra mjera rizika vrijednosnice koja se drži u dobro diverzificiranom portfelju kovarijanca portfelja i tržišnog portfelja. Stoga je za odluke menadžera kovarijanca prava mjera rizika. Radi jasnoće mjere rizika razvijena je beta kao relativna kovarijanca. Beta je relativna mjera rizika koja pokazuje osjetljivost promjene povrata vrijednosnice na promjene povrata tržišnog portfelja.

Beta pokazuje tendenciju pojedinačne vrijednosnice da kovarira s tržištem, stoga ima relativno značenje kao mjerilo za tržišni indeks čija vrijednost iznosi 1. Povrat na dionicu koja ima betu 1 raste i pada u istom postotku kao i tržišni portfelj.

Imovina koja ima vrijednost bete veću od 1, rizičnija je od tržišta (agresivna investicija) jer raste i pada više nego tržište. Ona, koja ima manju od 1, manje je rizična od tržišta (defazivna investicija). Ako je beta npr. 1,3 to znači da povrat na dionicu 1,3 puta više reagira u odnosu na tržišna kretanja.³³

Visina beta koeficijenta se može dovesti u vezu s osnovnim karakteristikama poduzeća kao što su: vrsta djelatnosti, stupanj operativne poluge te stupanj financijske poluge.

³³Aljinović, Z. (2009): Financijsko modeliranje, autorizirana predavanja, Ekonomski fakultet u Splitu

- Vrsta djelatnosti - što je djelatnost poduzeća osjetljivija na stanje i promjene tržišta, to je viša i njegova beta.
- Stupanj operativne poluge - pokazuje vezu fiksnih i ukupnih troškova poslovanja poduzeća. Poduzeća koja imaju veliki udio fiksnih troškova u ukupnim troškovima imaju osjetljiviju i promjenljiviju operativnu dobit. Što je promjenljivost operativne dobiti veća, to će uz ostale nepromjenjene faktore poduzeće imati višu betu.
- Stupanj financijske poluge - povećanje financijske poluge odnosno, povećanje udjela tuđih fiksnih izvora financiranja u ukupnoj financijskoj strukturi uz ostale nepromjenjene faktore, rezultirat će povećanjem beta koeficijenta. Uz visok stupanj financijske poluge, neto dobit će biti veća u razdoblju dobrog poslovanja, a manja u vrijeme ekonomskog pada i ta će se činjenica odražavati prosječno višim betama takvih poduzeća.

Beta koeficijente je moguće izračunati analizom regresije, te putem statističkih pokazatelja koji mjere odnose dviju varijabli kao što su kovarijanca, koeficijent korelacije i koeficijent determinacije.

Zadaća analize regresije je da pronade analitičko-matematički oblik veze između jedne ovisne ili regresand varijable i jedne ili više neovisnih ili regresorskih varijabli. Beta koeficijent je svakako najvažniji faktor ove funkcije koji pokazuje za koliko će se promjeniti povrat dionice n ako se povrat tržišta promjeni za 1%.

Kovarijanca je statistička mjera koja pokazuje kako se dvije promatrane varijable (u ovom primjeru povrat dionice i povrat tržišta) kreću u odnosu jedna prema drugoj. Kada je poznata kovarijanca između povrata dionice i tržišta, moguće je izračunati beta koeficijent uz pomoć izraza:

$$\beta_n = \frac{COV_{nm}}{\sigma_m^2} \quad (22)$$

gdje su:

β_n – beta koeficijent dionice n

COV_{nm} – kovarijanca povrata dionice n i tržišta m

σ_m^2 – varijanca tržišnog portfelja m .

Dakle, beta koeficijent stavlja u odnos kovarijancu povrata dionice i povrata tržišta sa varijancom tržišta.

Koeficijent korelacije je standardizirana mjera kovarijance. Njegova je praktičnost to što pokazuje smjerove kretanja dviju varijabli i jakost njihove veze. Koeficijent korelacije uvijek je između -1 i +1. Ako je izračunati koeficijent korelacije +1, tada je riječ o perfektnoj pozitivnoj korelaciji, odnosno kada se jedna varijabla poveća i druga se poveća za jednaki iznos. u slučaju kada je koeficijent korelacije -1, tada je riječ o perfektnoj negativnoj korelaciji, odnosno kada se jedna varijabla poveća, druga se smanji za isti iznos.

Koeficijent determinacije, poznatiji kao R^2 pokazuje koliki je dio promjena u povratima dionice uzrokovan promjenama u povratima tržišta. Koeficijent determinacije kaže koliko je % sume kvadrata odstupanja vrijednosti varijable Y od aritmetičke sredine protumačeno regresijskim modelom. Npr. ako je $R^2 = 0,61$, to znači da je 61% promjena povrata dionice objašnjeno promjenama u tržišnom povratu, a ostatak je uzrokovan ostalim faktorima koji se diverzifikacijom mogu eliminirati. Koeficijent determinacije se kreće u intervalu $0 \leq r^2 \leq 1$. Regresijski model je reprezentativniji ako je pokazatelj bliži 1.

Prije same procjene beta koeficijenata mora se riješiti nekoliko pitanja o samom postupku procjene:

- Pitanje dužine vremena procjene – hoće li se za procjenu koristiti podaci iz prošle godine ili iz nekoliko prošlih godina?
- Pitanje dužine intervala povrata – hoće li se mjerivi povrati kao dnevni, tjedni, mjesečni ili godišnji povrat?
- Pitanje izbora tržišnog indeksa – koje najbolje reprezentira ponašanje tržišta?
- Pitanje problema trženja dionicom – što ako se dionicom ne trguje često?

Izbor dužine vremena razdoblja procjene odredit će kvalitetu i preciznost analize regresije. Duže vremensko razdoblje rezultirati će beta koeficijentom zasnovanim na više opažanja. S druge strane, u dužem vremenskom razdoblju, moguće su promjene u ekonomskim karakteristikama poduzeća, kao što su financijska poluga ili promjena osnovne djelatnosti. Također, poduzeće može promijeniti svoje karakteristike rizika, pa proračun beta rizika neće dati pravu predodžbu o njegovom stvarnom sistemskom riziku.

Kraći vremenski intervali mogu rezultirati većom nepreciznosti beta koeficijenta zbog pogreške do koje dolazi kod dionica kojima se ne trguje svakodnevno. Beta koeficijenti dionica kojima se ne trguje svakodnevno imaju tendenciju podcijenjenosti kad su intervali mjerenja dnevni ili tjedni (mogu biti: ispod dnevnih, dnevnih, mjesečnih i godišnjih).³⁴

³⁴ Dadić M. (2011): „Beta koeficijenti kao mjera rizika i povrata pri ulaganju u odabrane dionice na ZSE“, diplomski rad, Sveučilište u Splitu, Ekonomski fakultet Split.

3. BREXIT

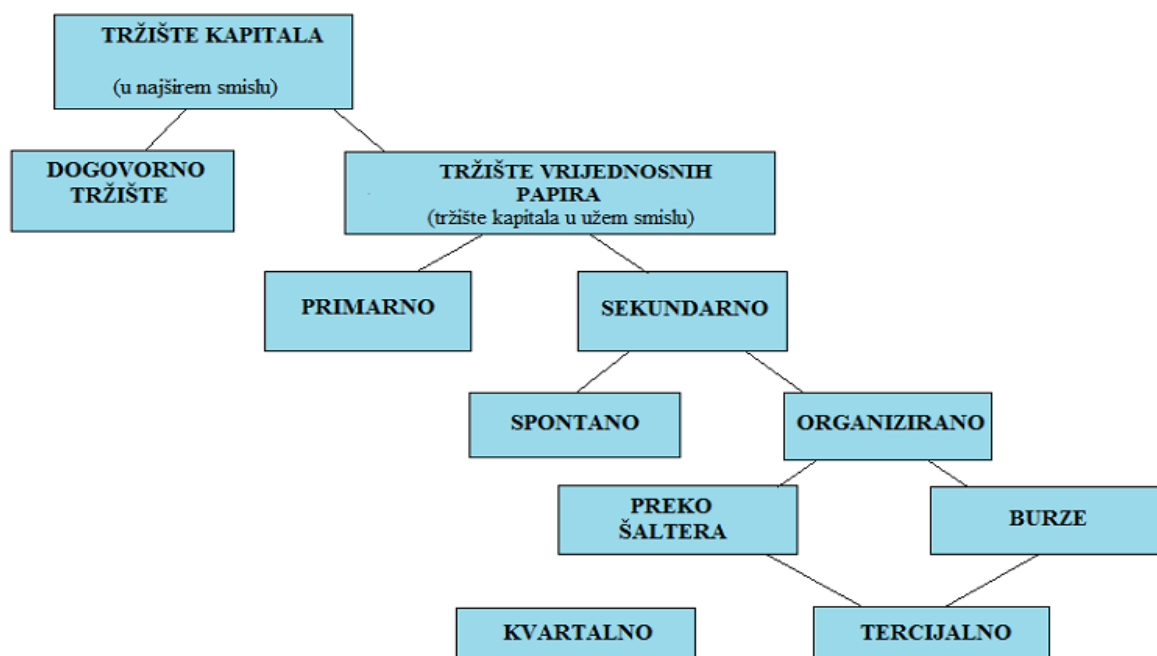
3.1. Britansko tržište kapitala

Financijsko tržište se može definirati kao mjesto na kojem se susreću ponuda i potražnja financijskih sredstava. Promet financijskim sredstvima odvija se korištenjem određenih financijskih instrumenata. Financijski instrumenti su ugovori u kojima su sadržana prava i obveze iz nekog financijskog odnosa. Stoga se financijsko tržište može definirati i kao mjesto na kojem se obavlja promet financijskim instrumentima. Financijska tržišta obavljaju nekoliko važnih funkcija nužnih za razumijevanje funkcioniranja mehanizma potrošnje i štednje te mehanizma financijskih i realnih investicija. Prva značajna funkcija tih tržišta jest vremensko usklađivanje potrošnje pojedinaca, a druga je omogućavanje povećanja sadašnje vrijednosti potrošnje pojedinca. Konačno, da bi se omogućila veza financijskih i realnih investicija, nužna je i funkcija tržišta kapitala koja omogućava usklađivanje različitih interesa mnoštva sudionika tih tržišta tako da vrijednost dionice postane temeljni motiv poslovanja javnih dioničkih društava.

Budući da tržište kapitala operira s financijskim proizvodima (imovinama ili aktivama) i da je u središnjici njegove funkcije financiranje gospodarstva, ono se u užem smislu redovito naziva i financijskim tržištem. Kada se spomene tržište kapitala, česta asocijacija je na burzu vrijednosnica. Tržište kapitala određeno je kao tržište dugoročnih vrijednosnih papira te se može raščlanjivati na više načina u zavisnosti od izbora kriterija. U najširem smislu tržište kapitala obuhvaća dogovorno tržište dugoročnih kredita i glavnice, te tržište dugoročnih vrijednosnih papira. Tržište dugoročnih vrijednosnih papira je tržište kapitala u užem smislu. Ovisno o tome pojavljuju li se vrijednosni papiri prvi put na tržištu ili se preprodaju, razlikujemo primarno i sekundarno tržište kapitala. Primarno tržište je naziv za trgovinu vrijednosnih papira, poput dionica i obveznica u trenutku njihovih izdavanja. Sekundarno tržište je naziv za tržište na kojem se obavlja promet već izdanih vrijednosnih papira. Operacije na tržištu kapitala mogu se odvijati spontano ili pak organizirano odnosno dijele se na izvanburzovna i burzovna tržišta. Izvanburzovna OTC tržišta (eng. Over the counter) su tržišta na kojima dileri koji posjeduju određenu zalihu vrijednosnih papira, nemaju fiksno mjesto trgovanja, te podrazumijevaju labaviju organizacijsku strukturu i pravila trgovanja.

Burzovna tržišta su uređena tržišta gdje se kupci i prodavatelji vrijednosnica susreću na jednom mjestu radi obavljanja trgovine. Glavna razlika između izvanburzovnih i burzovnih tržišta je u transparentnosti, odnosno podaci potrebni za donošenje odluka o investiranju na burzama su dostupni svima na jednak način, dok na OTC tržištima nisu. Organizirano tržište se dijeli na tržište preko šaltera i na burze. Tržišta preko šaltera omogućuju manjim poduzećima, čije vrijednosnice nisu uvrštene na redovnu burzu da za svoje dionice formiraju cijenu na slobodnom tržištu. Tako izbjegavaju troškove burzovnog uvrštenja na neko od velikih tržišta. Burza označava tržište vrijednosnica. U SAD-u su se 60-tih godina razvila tercijalna i kvartalna tržišta koja su vezana uz sekundarno tržište kapitala. Tercijalno tržište kapitala predstavlja sponu između organiziranog trgovanja vrijednosnim papirima na burzi trgovanja i na OTC tržištu. Na njemu se odvijaju kupoprodaje dionica uvrštenih na burzi preko dilerskih šaltera. Kvartalno tržište kapitala služi za trgovanje velikim blokovima vrijednosnih papira i služi za trgovinsku mrežu između institucionalnih investitora. Pored toga kvartalno tržište smanjuje transakcijske troškove i smanjuje utjecaje velikih transakcija na cijene vrijednosnih papira na tržištu.³⁵

Navedeno je prikazano na slici 9.



Slika 9: Struktura tržišta kapitala

Izvor: Izradio autor

³⁵Orsag S.,Dedi L.,(2014):"Tržište kapitala", Zagreb:Alka script, str. 138

Londonska burza (London Stock Exchange – LSE) je najpoznatije i najznačajnije tržište kapitala u Britaniji, odnosno u cijeloj Europi, te je po opsegu trgovanja treća burza u svijetu. Burza je stara preko 300 godina, te je kao takva i jedna od najstarijih na svijetu. Povijest burze datira još iz 1571. godine kada je engleski financijer Sir Thomas Gresham osnovao The Royal Exchange - kraljevsku burzu, službeno mjesto za tržište koje je svečano otvorila kraljica Elizabeta I. Zbog strogih propisa mnogi brokeri nisu imali pristup burzi, te su svoje trgovanje vrijednosnim papirima obavljali u neposrednim ulicama i gostionicama.³⁶ Jedan od brokera koji nije imao pristup kraljevskoj burzi bio je i John Casting koji je 1698. godine u obližnjoj gostionici *Johnatan's Caffé* prvi put izdao detaljan popis tržišnih cijena nekih najvažnijih proizvoda poput ugljena, soli i papra. Popis se nije osvježavao na dnevnoj bazi, već je bio objavljivan dva puta tjedno, svaki utorak i petak. Detaljni popisi tržišnih cijena su najstariji dokazi o organiziranom trgovanju, stoga se 1698. godina smatra godinu osnutka Londonske burze. Tokom 18. stoljeća Britanski parlament je donio zakon kojim je broj brokera bio ograničen na najviše 100. Rastom tržišta proporcionalno se povećalo i trgovanje vrijednosnicama na ulicama Londona unatoč zabranama i financijskim te fizičkim kažnjavanjima. 1801. godine u Londonu je osnovana prva službena burza nazvana *Subscriptionroom* (potpisnička soba) koja je imala svoj pravilnik. No prvog dana trgovanja je došlo do problema zbog pojavljivanja trgovaca bez dozvole, što je utjecalo na donošenje odluke o izgradnji nove zgrade londonske burze. Nova zgrada je otvorena tokom iste godine s uklesanim natpisom na ulazu zgrade „The Stock Exchange“. Kroz 19. stoljeće donesen je novi pravilnik burze koji je unio značajan red u trgovanje, a izum i uporaba telefona i telegrafa su dodatno unaprijedili burzovno poslovanje. Trgovanje burzama je postalo veoma zastupljeno u Londonu. Stalno povećanje trgovaca i članova burze je stvaralo velike gužve u poslovanju zbog čega je donesena odluka o izgradnji nove zgrade koja je imala dvostruko veći prostor za trgovanje. Ratno vrijeme u prvoj polovici 20. stoljeća utjecalo je na zastoј daljnjeg razvijanja burze. Burza je za vrijeme dvaju svjetskih ratova bila i zatvarana zbog bojazni od napada i naglog pada cijena vrijednosnica. Nakon ratova ponovno dolazi vrijeme stabilizacije i povećanja burzovnog trgovanja. Vlasti ponovno donose odluku o izgradnji novog i većeg prostora za trgovanje, te 1972. godine kraljica Elizabeta II. otvara novi poslovni toranj visok preko 100 metara koji predstavlja jedan od novih simbola grada. Godina nakon je veoma bitna prekretnica u poslovanju burze. Naime, donesen je zakon koji dopušta ženama i strancima trgovanje na burzi. Londonska burza se formalno udružuje s regionalnim

³⁶<http://www.walklondon.com/london-attractions/royal-exchange.htm>

burzama iz Britanije i Irske, te po prvi put počinje djelovati pod imenom The London Stock Exchange. Do najveće deregulacije tadašnjeg poslovanja zbilo se 1986. godine poznatije pod nazivom „Big Bang“ kada je dozvoljeno da dionice međunarodnih tvrtki mogu kotirati na londonskoj burzi. Promjene su se odnosile i na način poslovanja u kojem je direktno trgovanje „face to face“ zamjenjeno elektroničkim trgovanjem, te novi način pravednog distribuiranja informacija potrebnih za regularno obavljanje transakcijskih poslova. 1984. godine uveden je burzovni indeks FTSE 100 poznat i po imenu FOOTsie, koji prati kretanje 100 vodećih tvrtki koje kotiraju na burzi. Novu povijest Londonske burze koje predstavlja razdoblje novog tisućljeća obilježava uvođenje niza novih financijskih proizvoda i novina u trgovanju. Trgovanje se obavlja elektroničnim putem, stoga je burzovni toranj postao suvišan.³⁷ 2004. godine londonska burza se seli na PaternosterSquare nedaleko od katedrale svetog Pavla gdje se nalazi i danas. 2007. godine londonska burza se spaja sa organizacijom Bursa Italia te se tako formirala grupa nazvana London Stock Exchange Group - LSEG. Nakon toga je bilo još nekoliko pokušaja spajanja s američkim, kanadskim i njemačkim tržištima kapitala, no ti se poslovni pothvati nisu realizirali.

3.1.1. Temeljne odrednice londonske burze³⁸

Londonska burza (Eng. London Stock Exchange) je najznačajnija europska burza vrijednosnih papira i treća burza na svijetu po opsegu poslovanja. U siječnju 2017. godine na Londonskoj burzi kotirale su dionice od 2,261 kompanija iz više od 50 zemalja diljem svijeta, a njihova ukupna vrijednost bila je 4.5. milijarda funti.³⁹ Londonska burza pruža mogućnost pristupa kapitalu za široki raspon domaćih, ali i međunarodnih tvrtki. Burza u Londonu omogućuje da njeni članovi budu i društva u stranom vlasništvu, a burza ukupno ima preko 5000 članova koji su organizirani u preko 350 kompanija-članova. Te kompanije su iz različitih sektora, ali primat ima informacijska tehnologija, zatim elektronika, financije, maloprodaja i industrija. Članovi se biraju svake godine, a od njih se očekuje ispunjavanje visokih standarda ponašanja, te ukoliko član nije u mogućnosti ispuniti sve svoje obveze, to se

³⁷C. R. Michie: The London Stock Exchange: „A History“, Oxford: OxfordUniversityPress, 1999. godina

³⁸Bazirano na: <http://www.londonstockexchange.com/home/homepage.htm>

³⁹<http://www.londonstockexchange.com/statistics/historic/company-files/company-files.htm> 25.2.2017

javno objavi i time prestaje njegovo članstvo na burzi. Cijena članarine u 2015. godini je bila 12 500 funti.⁴⁰ Temeljne vrijednosti londonske burze su poštenje, partnerstvo s kupcima, izvrsna usluga i inovacija što se podudara sa glavnom vodikom burze koja glasi „Dictum meum pacum“ što znači „Moja riječ me obavezuje“. Londonska burza je od 1986. godine dioničko društvo, no prema svome statutu dobit se ne smije podijeliti dioničarima. Dioničari londonske burze biraju Upravu i Savjet koji biraju predsjednika i dva podpredsjednika te su pod njihovom integracijom poslovi organizacije trgovanja, uvođenja novih vrijednosnica i sl. 1986. godina predstavlja prekretnicu u poslovanju burze poznatu kao „Big Bang“. Razvijanje najnovije računalne tehnologije, uz poboljšanje burzovnih propisa, omogućilo je brokerima da zamjene tadašnju direktnu prodaju sa elektroničnim trgovanjem. Danas se trgovanje odvija elektroničkim putem, a radno vrijeme burze je od ponedjeljka do petka od 8.00h do 16.30h. Na Londonskoj burzi se trguje dionicama, obveznicama (i sličnim vrijednosnicama) i Depository Receipts- potvrđama o vlasništvu dionica inozemne kompanije.

Na londonskoj burzi postoji još nekoliko elektronskih platformi koje su prilagođene određenim sustavima vrijednosnica, a to su:

- (Stock Exchange Automate Quotations –SEAQ) - automatizirane burzovne kotacije. Njihova namjena je trgovanje na alternativnom investicijskom tržištu (Alternative Investment Market –AIM)
- (SETS) - sustav elektroničke knjige za trgovanje najlikvidnijih i najvrijednijih dionica.
- (SETSm) - sustav elektroničke knjige ili hibridni sustav za trgovanje dionica male ili srednje kapitalizacije. On kombinira elektroničku knjigu naloga i aktivnu ulogu održavatelja tržišta koji se međusobno natječu, s ciljem postizanja najbolje moguće cijene.
- (SEATS Plus) - platforma za trgovanje najslabije likvidnim vrijednosnicama.

Uz povoljni geografski položaj, te povijest poslovanja londonska burza je dodatno unaprijedila poslovanje te ostala financijsko središte Europe, te jedna od vodećih burzi u svijetu.

⁴⁰http://www.lseg.com/sites/default/files/content/documents/Membership%20Price%20List%202015_0.pdf

3.1.2. Indeksi londonske burze

Burzovni indeksi prikazuju promjenu u cijenama dionica od kojih se indeks sastoji, odnosno on je poput sažetka burzovnog poslovanja. Indeksi pružaju općenite informacije potencijalnim investitorima, djelatnicima burze, financijskim stručnjacima i drugima o kretanjima na tržištu kapitala te služe za procjenu tržišnih kretanja kroz određeni vremenski period. Burzovni indeksi se uglavnom sastoje od većih broja dionica, a najpoznatiji svjetski burzovni indeks je Dow Jones Industrial Average (DJIA) koji se sastoji od 30 najvećih američkih tvrtki. Među burzovnim indeksima sljedeći indeks po važnosti je S&P500 koji obuhvaća kretanja cijena 500 najvećih tvrtki koje se nalazi na burzi u New Yorku. Zatim treba spomenuti Britanski FTSE 100, Njemački DAX, Japanski NIKKEI, dok je CROBEX indeks zagrebačke burze. Najveća poduzeća koja djeluju na svjetskoj razini, najbrže osjete gospodarske i političke promjene koje se događaju, što se u konačnici odražava i na promjenama burzovnih indeksa.⁴¹

Burzovni indeks FTSE 100 poznat kao i FOOTsie je kompjuterizirani indeks sastavljen od 100 velikih britanskih tvrtki, koje se često nazivaju i „bluecheap“⁴² tvrtke i obuhvaćaju preko 80 posto ukupnog trgovanja na burzi. Nastao je kao nasljednik indeksa FT 30, koji je uveden 1935. godine i jedan je od najstarijih burzovnih indeksa u svijetu, iako se danas rijetko koristi. FTSE 100 je na londonsku burzu (LSE) uveden je 3. siječnja 1984. godine od strane Financial Timesa, te je bio 50% u vlasništvu londonske burze i 50% u vlasništvu Financial Timesa po kojima indeks i dobiva ime (F- Financial, T - Times, S - Stock, E- Exchange). Početna vrijednost indeksa je bila 1000 bodova. Najveću vrijednost FTSE indeks je imao 2. ožujka 2017. godine kada je iznosio 7382,9 poena⁴³, dok je najniža vrijednost indeksa bila iste godine kada je i uveden, na datum 12. srpnja 1984. godine i iznosio je 978,7. Najveći jednodnevni postotni pad dogodio se 20. listopada 1987. godine i iznosio je 12,22%, te je nazvan „crni ponedjeljak“. Vrijednost indeksa kroz povijest je varirala sukladno stanjima u gospodarstvu. Gospodarski razvitak koji je obilježio kraj 90-tih godina 20. stoljeća, reflektirao se na vrijednost indeksa koja je početkom 2000. godine iznosila 6950 poena, dok je tijekom posljednje gospodarske krize u razdoblju od 2007. do 2010. godine vrijednost FTSE 100 indeksa oslabila i kretala se oko 3500 poena.

⁴¹<http://finance.hr/tournament/burzovni-indeksi/> 1.3.2017.

⁴² „bluecheap“ dionice predstavljaju dionice kompanija koje imaju velik ugled i tržišnu poziciju, te slove kao kvalitetne i stabilne i u doba velikih kolebanja cijena vrijednosnica na burzama.

⁴³<http://www.bbc.com/news/business-39125987> 2.3.2017

Kao što je već navedeno, FTSE 100 indeks se sastoji od 100 najvećih tvrtki s londonske burze. Sastav vrijednosnica indeksa se ažurira 4 puta godišnje, odnosno na kvartalnoj bazi. To se događa svake srijede iza prvog petka u mjesecu ožujku, lipnju, rujnu i prosincu. Postupak ocjenjivanja indeksa tvrtki za određivanje 100 najboljih kompanija koje će biti u sustavu indeksa FTSE 100 se izračunava na sljedeći način:⁴⁴

$$\text{Indeks level} = \frac{\sum (\text{Price od stock} * \text{Number of shares}) * \text{Free float factor}}{\text{Index Divisor}} \quad (23)$$

Ako tvrtka koja se nalazila među 100 najboljih više nije u tom krugu, ona pada u indeks FTSE 250, i obrnuto. Indeks FTSE 250 predstavlja sljedećih 250 najvećih tvrtki nakon FTSE 100. Mnogi analitičari smatraju da je indeks FTSE 250 bolji pokazatelj britanskog gospodarstva naspram indeks FTSE 100, zbog činjenice da potonji indeks sačinjavaju velike međunarodne tvrtke, dok je udio međunarodnih tvrtki manji u indeksu FTSE 250. Indeksi FTSE 100 i FTSE 250 zajedno čine indeks FTSE 350. Navedeni indeksi su u vlasništvu FTSE grupe i oni se izračunavaju svakih 15 sekundi u radnom tjednu.⁴⁵

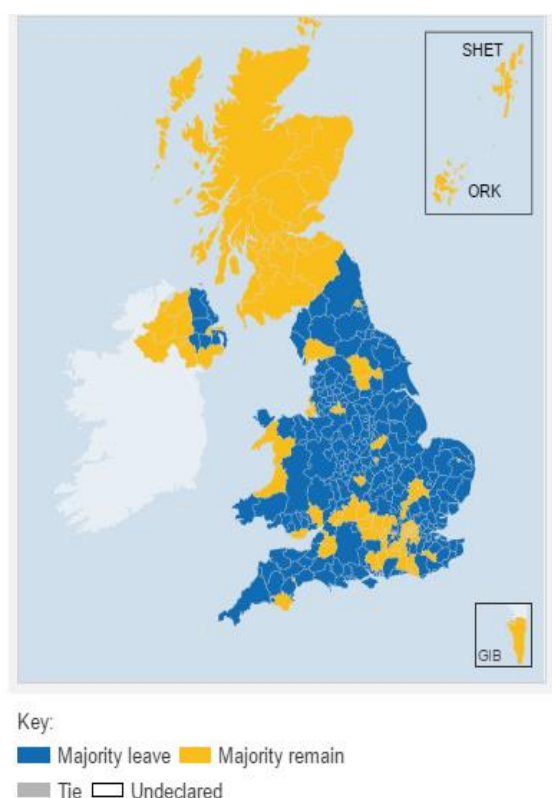
FTSE grupa pruža i upravlja čitavim nizom indeksa na britanskom tržištu kapitala kojim se mjeri uspješnost cjelokupnog, ali i pojedinačnih sektora gospodarstva u Velikoj Britaniji. Pored navedenih indeksa treba još spomenuti FTSE All-Share (uključuje indekse FTSE100, FTSE 250 i FTSE SmallCap) koji se sastoji od preko 600 tvrtki kojima se trguje na londonskoj burzi i predstavlja 98% ukupne vrijednosti kapitala tvrtki čije dionice kotiraju na burzi.

⁴⁴[http://www.wikininvest.com/indeks/FTSE_100_Indeks_\(FTSE\)](http://www.wikininvest.com/indeks/FTSE_100_Indeks_(FTSE))

⁴⁵<https://www.share.com/new-to-investing/the-ftse-100-what-does-it-all-mean/> 2.3.2017

3.2. Brexit i njegov utjecaj na britansko tržište kapitala

Riječ Brexit počela se koristiti kao skraćenica za izlazak Velike Britanije iz Europske unije, a nastala je spajanjem dviju riječi Britain (Velika Britanija) i exit (izlaz). Nastala je na isti način kao i riječ „Greksit“ koja se koristila za mogući izlazak Grčke iz Europske unije. Referendum, u kojem se odlučivalo da li Velika Britanija treba napustiti Europsku uniju dogodio se 23. lipnja 2016. godine. Na referendumu su mogli glasati Britanski, Irski i građani zajednice Commonwealtha koji imaju prebivalište u Velikoj Britaniji i da su stariji od 18 godina, te britanski građanikoji su živjeli u inozemstvu manje od 15 godina. Rezultat referenduma je bio 51,9% za izlazak iz EU odnosno 48,1% za ostanak. Izlaznost na referendum je bila veoma velika, preko 70%. Statistički promatrani rezultati predočavaju veliku podijeljenost unutar Velike Britanije. Stanovnici većih mješovitih gradova i Sjeverne Irske i Škotske su glasali za ostanak, dok je srednji dio Engleske i Walesa glasao za izlazak iz EU.



Nation results

England



Northern Ireland



Scotland



Wales




Slika 10. Rezultati referenduma o Brexitu

izvor: http://www.bbc.com/news/politics/eu_referendum/results

Pristaše Brexita su u središte svoje kampanje stavili izbjeglički val sa Bliskog istoka koji je stvarao strah među britanskim građanima od širenja njihove vjere i terorističkih napada. Pored toga građanima bi bila upitna njihova radna mjesta s dolaskom nove jeftinije radne snage. Također se može uočiti kako je većinsko starije stanovništvo s pravom glasa i stavom protiv EU nadglasalo mlađe stanovnike između 18 i 24 godine koji su bili za ostanak u Europskoj uniji i tako utjecali na njihovu budućnost koju oni ne žele.

How different age groups voted



Slika 11. Rezultati Brexita po dobnim skupinama

Izvor: <http://www.bbc.com/news/uk-politics-36616028>

Mnogi smatraju kako su politika i mediji odigrali ključnu ulogu za konačne rezultate, ali je velik utjecaj imala i povijest Velike Britanije. Naime, britanci su kroz povijest imali jake osjećaje neovisnosti i nacionalne pripadnosti te su uvijek imali podcjenjivački odnos prema zemljama kontinentalne Europe. Kroz povijest je Velika Britanija bila velika svjetska imperijalna sila koja je imala tradiciju neulaženja u uniju s drugim zemljama. Kao takva sila uspjela je prebroditi svjetske ratove, no nakon njih je zemlja počela stagnirati ekonomski, politički i tehnološki što je navelo da pristupi preteči Europske unije, u Europsku ekonomsku zajednicu 1. siječnja 1973. godine. Već je 1975. godine je bio održan referendum o izlasku Velike Britanije iz Europske ekonomske zajednice u kojem je 67% britanaca glasalo za ostanak, a 33% za izlazak iz EEZ. U razdoblju između dva navedena referenduma, dakle od

1975. do 2016. godine na političku scenu bi se javljale pojedine stranke koje su se protivile Europskoj uniji i imale velik broj pristaša. Kada je David Cameron postao premijer Velike Britanije obećao je narodu da će se za njegova mandata održati konačni referendum o tome da li žele da Velika Britanija napusti EU, što se u konačnici i dogodilo 23. lipnja 2016.

Nekoliko dana prije održavanja referenduma, rezultati iz anketa pokazali su izjednačenost između zagovornika ostanka i izlaska Britanije iz EU. Mnogi analitičari su se izjasnili da će izlazak iz EU imati mnoge negativne utjecaje na cjelokupno gospodarstvo. U prvom redu posljedice bi se mogle očitovati na pad britanske funte, oslabiti će se trgovački trendovi, kompanije će vjerojatno smanjiti investicije zbog nesigurnosti što će u konačnici dovesti do povećanja nezaposlenosti. Brexit bi mogao dovesti do novih mogućih referenduma kojim bi ponajprije Škotska i Sjeverna Irska tražile izlazak iz Ujedinjenog Kraljevstva Velike Britanije i Sjeverne Irske.

Izlaskom rezultata referenduma sva predviđanja su se obistinila. Britanska funta je pala za 10% u odnosu na američki dolar, odnosno na 1,3228 dolara, što je najniža razina vrijednosti od 1985. godine. Ulagачi su se užurbano povlačili iz rizičnih investicija, kao što su dionice i tražili utočište u onima koji se smatraju sigurnijima što je utjecalo na oštar pad cijena dionica. „Bit će to ružno jutro. Ovakav ishod referenduma mnoge je ulagače uhvatio na krivoj nozi“ rekao je Mike Ellingsen, analitičar u tvrtki U.S. Global Investors.⁴⁶ Londonski FTSE 100 je izgubio oko 500 bodova s indeksa, dok je FTSE 250 kojije bolji pokazatelj britanskog gospodarstva izgubio oko 11.4%. što se nazvalo crni petak na burzi. Pod velikim pritiskom je bilo i poslovanje britanskih banaka Lloydsa, Royal bank of Scotland i Barclaysa koje su potonule zaviše od 22%. Samo na londonskoj burzi zbog pada cijena dionica izbrisano je oko 100 milijardi funta tržišne vrijednosti kompanija i banaka. Mnogi analitičari su smatrali da će odlukom o napuštanju Unije najvjerojatnije rezultirati recesijom u Britaniji. To bi dodatno trebala potaknuti inflacija za koju se predviđa da će postići razinu između 2% i 4%. Sukladno tome smanjila bi se i ulaganja čiji se pad očekuje u rasponu od 15% do 20%. Nepovoljan utjecaj ulaganja reflektirao bi se na nova radna mjesta, plaće i nezaposlenost. Britanski ministar financija George Osborne je najavio gubitak državnog proračuna nakon Brexita od gotovo 37 milijardi eura u sljedeće 4 godine. Da bi se pokrio taj minus najavio je podizanje

⁴⁶<http://direktno.hr/svijet/eu/vec-vidljivi-rezultati-brexit-europske-burze-potonule-vise-od-8-posto-52247/>

poreza čime bi svaki Britanac godišnje izgubio oko 3000 eura BDP-a po stanovniku, odnosno pao bi sa 38 000 na 35000 eura.

Kako bi spriječili negativna predviđanja za gospodarstvo i monetarnu stabilnost, britanska središnja banka Bank of England je snizila kamatne stope sa 0,5% na rekordno niskih 0,25%. Dodatno je najavljeno kako će kupovati državne obveznice kako bi se dodatno ublažile posljedice referendumske odluke i postigla stabilnost. Nakon što se tržište stabiliziralo, predviđanja mnogih analitičara su se pokazala krivima. Pad funte koji se dogodio je bio očekivan i vrijednost funte je dosegla najnižu razinu od 1985. godine, no funta nije jedino ekonomsko mjerilo koje će gurnuti gospodarstvo u recesiju. Naprotiv, pad funte se reflektirao potpuno drugačije. Izvoz je porastao za 2 milijuna funti, dok se uvoz smanjio za 1,8 milijardi funti. Mjere koje je poduzela središnja banka Britanije kako bi održali stabilnost gospodarstva utjecale su na značajni rast potrošnje uslužnog sektora nakon Brexita. Pad funte je zasigurno i utjecao na veći broj turista koji su posjetili Veliku Britaniju nakon referenduma. Navedeno uz niz drugih faktora utjecalo je veći rast gospodarstva od predviđenog sa 2,0% na 2,1%. Isto tako Bank of England je povisila prognozu za gospodarski rast u 2017. godini sa 0,8% na 1,4%. Dionice na burzama su također suprotno predviđanjima narasle i dostigle rekordne vrijednosti. FTSE 100 je na kraju godine ostvario porast od 14,4% tijekom godine, a indeks FTSE 250 koji je bolji pokazatelj britanskog gospodarstva je narastao za 3,7%. Također, nezaposlenost je bila na rekordno niskim razinama.

Mnogi analitičari usprkos pozitivnim pokazateljima smatraju da su pad gospodarstva i recesija neizbježni. Pri tome smatraju da Velika Britanija još nije osjetila nikakve gubitke u financiranju iz raznih EU fondova, što će se po stupanju na snagu referenduma dogoditi. Smanjenje kamatne stope na niskih 0,25% također smatraju prijetnjom za gospodarstvo u budućnosti. Što će se u budućnosti događati s britanskim gospodarstvom nemoguće je predvidjeti jer to ponajviše ovisi o složenim izlaznim pregovorima koji će se odvijati u naredne 2 godine između Velike Britanije i Europske unije.⁴⁷

⁴⁷<http://www.bbc.com/news/business-36956418> 5.3.2017.

3.3 Brexit i njegov utjecaj na EU i svijet

Neočekivani rezultati referenduma kojim je izglasan izlazak Velike Britanije iz EU iznenadio je cijeli svijet. Mnogi znanstvenici smatraju da će rasponi mogućih posljedica Brexita bit jako veliki u svim pokazateljima. Posljedice referenduma snažno će utjecati na europsko gospodarstvo i financijsku industriju. Financijski sektor se smatra posebno ugroženim zbog velike koncentracije financijskih usluga u Britaniji i činjenice da se gotovo 80% svih financijskih transakcija EU inicira u toj zemlji. Sami rezultati su dokazali predviđanja. Naime, pod najvećim pritiskom nakon referenduma je bio europski bankarski sektor u kojem su dionice pale za 15% te tako zabilježio jedan od najvećih dnevnih padova u povijesti. Kako bi neutralizirale početne neizvjesnosti središnje banke odlučile su se za politiku zadržavanja niskih kamatnih stopa.

Također odluka Britanije o izlasku iz EU je izazvala pad indeksa na europskim tržištima između 5% i 10%, a pad indeksa se osjetio i na Wall Streetu. Smatra se da je na dan odluke o izlasku na svjetskim burzama izbrisano više od 2.000 milijardi dolara vrijednosti dionica od čega je 1.000 milijardi na europskim burzama. Njemački indeks DAX je pao 8%, Francuski CAC 40 je izgubio 10%, a u Italiji i Španjolskoj burzovni indeksi su pali i više od 10%. Negativni rezultati su zahvatile burze i u ostatku svijeta. Na burzi u New Yorku Dow Jones i S&P 500 indeksi su pali za više od 2%, a Nasdaq indeks više od 3,5%. Brexit je utjecao i na pad dionica na azijskim burzama. Najveći gubitak je ostvario japanski indeks Nikkei s padom od gotovo 8% što je za njega bio najveći dnevni pad od potresa u Fukushimi 2011. godine te MSCI indeks azijsko-pacifičkih dionica koji je izgubio 5%. Odluke referenduma su se osjetile i na hrvatskoj burzi. Tijekom dana Indeksi zagrebačke burze su pali za više od 1%, uz znatno veći promet nego prethodnih dana.⁴⁸


Najveći utjecaj Brexita će imati EU, posebno zemlje članice koje imaju najbolje razvijene trgovinske i financijske veze s Britanijom. EU je najveći trgovinski partner u Velikoj Britaniji. Izlaskom Britanije iz EU bit će uklonjena slobodna trgovina i narasti će troškovi razmjene zbog carinskih barijera i viših tarifa što će utjecati na rast cijena dobara i usluga, a u konačnici i do smanjenja izvoza.

⁴⁸<http://www.vecernji.hr/gospodarstvo/krah-na-burzama-izbrisano-vise-od-2000-milijardi-dolara-vrijednosti-dionica-1094556> 7.3.2017

Amerika je također gubitnik od posljedica Brexita. Naime, Velika Britanija je Americi ulaznica u Europu u političkom i ekonomskom smislu. Stoga je stav Amerike bio protiv Brexita kako nebi izgubili utjecaj u Europi.

Pod pritiskom su i cijene nafte te drugih sirovina. S druge strane, cijena zlata je snažno porasla za gotovo 5% jer se smatra sigurnim utočištem naspram kapitala u nesigurnim vremenima.

Posljedice Brexita odraziti će se i na BDP i životne standarde drugih zemalja. Analitičari su u razmatranjima predstavili optimistične i pesimistične scenarije. Prema njima će EU izgubiti od – 0,12% do -0,29% BDP-a. Najveći pad BDP-a po stanovniku smatra se da bi bio u Irskoj zatim Nizozemskoj i Belgiji što je prikazano i na grafikonu.



Slika 12. Utjecaj Brexita na životne standardne drugih zemalja

Izvor: <http://cep.lse.ac.uk/pubs/download/brexit02.pdf>

Početak 2017.godine može se primjetiti kako je Brexit imao veći utjecaj na ekonomiju Europske unije nego Velike Britanije. Ipak su analitičari i dalje pri stavu da će u budućnosti veće posljedice Brexita biti za Veliku Britaniju, no pri davanju daljnjih prognoza treba biti oprezan. Najveću ulogu će zasigurno imati pregovori između Velike Britanije i Europske unije. S druge strane, ključnu ulogu će imati i centralne banke koje su reagirale zadržavanjem niskih kamatnih stopa kako bi neutralizirali neizvjesnosti. Niske kamate povoljno djeluju na tržište no pitanje je koliko će to još dugo trajati. Sigurno nas čeka neizvjesno razdoblje u kojem će sigurno doći do brojnih promjena i restrukturiranja.

4. FORMIRANJE PORTFELJA NA BRITANSKOM TRŽIŠTU KAPITALA

4.1. Dionice u sastavu portfelja

Portfelj na britanskom tržištu kapitala formiran je od deset dionica koje su u sastavu indeksa FTSE 100 na Londonskoj burzi. Indeks FTSE 100 je burzovni indeks koji se sastoji od 100 kompanija s Londonske burze koje imaju najveću tržišnu kapitalizaciju. Analizirani su podaci na tjednoj razini u vremenskom razdoblju od osam mjeseci prije nastupanja Brexita, te osam mjeseci nakon što je donesena odluka o napuštanju Europske Unije od strane Velike Britanije za sljedećih 10 dionica:

Tablica 1. Odabrane dionice sa Londonske burze vrijednosnih papira

Simbol dionice	Izdavatelj
BARC.L	Barclays
BRBY.L	Burberry
BT.L	BT Group
CCH.L	Coca Cola
GLEN.L	Glencore
LLOY.L	Lloyds Bank
RRS.L	Randgold Resources
REL.L	Relx
RR.L	Rolls Royce
SL.L	Standard life

Izvor: LSE

Odabrane su dionice poduzeća različitih sektora, sektorska podjela dionica vrši se na temelju djelatnosti pojedinog poduzeća koji izdaje dionice. Sektori koji su zastupljeni u portfelju su bankarski sektor kojem pripadaju dionice Barclaysa te Lloyds banke, automobilske industrije koju predstavlja Rolls Royce, te također sektor telekomunikacija, zlata, odjeće, informatike, osiguranja te prehrane.

4.2. Izračun mjera rizika za promatrane dionice

Mjere rizika korištene u radu su beta koeficijent i VaR. Beta pokazuje tendenciju pojedinačne vrijednosnice da kovarira s tržištem, stoga ima relativno značenje kao mjerilo za tržišni indeks čija vrijednost iznosi 1. Povrat na dionicu koja ima betu 1 raste i pada u istom postotku kao i tržišni portfelj. Imovina koja ima vrijednost bete veću od 1, rizičnija je od tržišta jer raste i pada više nego tržište, a ona, koja ima manju od 1, manje je rizična od tržišta.

Sljedeće dvije tablice prikazuju izračun bete za dva analizirana portfelja u kojima su jednaki udjeli svih dionica.

Tablica 2. Beta koeficijent za portfelj prije Brexita

	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
Kovarijanca	0,00043991	0,000313605	0,00019	0,000385	0,000922	0,000419643	0,000136011	0,00025	0,000582069	0,000331589
β	1,29364208	0,922207272	0,557461	1,131909	2,710186	1,234031558	0,399963287	0,736376	1,71167079	0,975091777
$\beta\pi$	-0,0104974									

Izvor: Izračun autora

Na temelju izračunatog beta koeficijenta možemo zaključiti da je najrizičnija dionica Glencora s betom 2,71 što je značajno veće od 1 dok je najmanje rizična u odnosu na tržište dionica Randgold Resourcesa sa betom 0,399.

Također je izračunata $\beta\pi$ odnosno beta portfelja sastavljenog od dionica s jednakim udjelima.

Tablica 3. Beta koeficijent za portfelj poslije Brexita

	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
Kovarijanca	5,59978E-05	0,000160148	0,000139	0,00012799	0,00011536	4,52778E-05	0,000110337	0,000129195	9,43459E-05	0,000148343
β	0,47771453	1,366215253	1,188994	1,09184779	0,98409827	0,386263023	0,941276678	1,102155472	0,804860398	1,265507243
$\beta\pi$	0,0562514									

Izvor: Izradio autor

Analiza beta koeficijenta za portfelj koji je formiran u vremenskom preiodu nakon Brexita pokazuje da je u odnosu na tržište najrizičnija dionica Burberrya s betom 1,36 dok je najmanje rizična dionica Lloyds banke s betom 0,386. Kao i za prethodno razdoblje izračunata je beta portfelja sastavljenog od dionica s jednakim udjelima i za razdoblje nakon Brexita.

Nakon provedene analize za oba promatrana razdoblja ne može se donijeti zaključak da je ulaganje u jednom razdoblju rizičniji nego u drugom. Dionice Barclaysa, Coca-Cole, Glencora, Lloyds Banka te RollsRoyca imaju manji beta koeficijent u razdoblju nakon Brexita, dok ostale dionice imaju manje beta koeficijente u razdoblju prije Brexita, stoga se na temelju bete ne može donijeti zaključak koje je razdoblje nosilo manji rizik za ulagače.

Druga korištena mjera rizika je VaR, a dobiveni rezultati prikazani su u sljedećim tablicama za oba formirana portfelja.

Tablica 4. VaR portfelja prije Brexita pri razini vjerovatnosti 95% i 99%

DIONICE	Uložena vrijednost	VaR 95%	VaR 99%
Barclays	10.000	1516,258	1952,628
Burberry	10.000	1482,958	1930,695
BT Group	10.000	681,8897	972,1518
Coca Cola	10.000	1018,368	1381,881
Glencore	10.000	2233,489	3076,517
Lloyds Bank	10.000	1195,46	1628,428
Randgold Resources	10.000	997,9589	1519,256
Relx	10.000	530,414	784,4533
Rolls Royce	10.000	1938,499	2582,647
Standard life	10.000	1042,373	1370,843

Izvor: Izračun autora

Na temelju provedene analize rizične vrijednosti uz razine pouzdanosti možemo zaključiti da se rizična vrijednost povećava s povećanjem razine pouzdanosti.

Najrizičnija dionica portfelja je dionica Glencora prema izračunatoj rizičnoj vrijednosti uz razinu pouzdanosti od 95 i 99%. Odnosno ukoliko bi investitor uložio 10 000 kuna u dionicu Glencorea na tjednoj razini uz razinu pouzdanosti 95% izgubio bi maksimalno 2233,489 kuna, dok bi za istu dionicu pri razini pouzdanosti od 99% na istoj uloženoj vrijednosti izgubio 3076,517 kuna. Najmanja rizičnost ulaganja pri obje razine pouzdanosti je u dionicu Relx-a.

Tablica 5. VaR portfelja poslije Brexita pri razini vjerovatnosti 95% i 99%

DIONICE	Uložena vrijednost	VaR 95%	VaR 99%
Barclays	10.000	324,3201	689,3693
Burberry	10.000	435,5322	779,1273
BT Group	10.000	1279,515	1684,201
Coca Cola	10.000	484,6704	784,6281
Glencore	10.000	376,4448	848,7637
Lloyds Bank	10.000	519,9695	862,0365
Randgold Resources	10.000	1542,705	2033,896
Relx	10.000	529,613	770,7036
Rolls Royce	10.000	871,2185	1247,599
Standard life	10.000	625,5635	998,3365

Izvor: Izračun autora

Ista analiza rizične vrijednosti provedena je i za portfelj formiran nakon odluke o Brexitu, te na temelju dobivenih rezultata pri razinama pouzdanosti od 95 i 99% možemo zaključiti da najveću rizičnu vrijednost ima dionica Randgold Resourcesa pri obje razine rizika.

Ukoliko bi investitor uložio 10 000 kuna u navedenu dionicu njegov maksimalni gubitak na tjednoj razini pri razini rizika od 95% bi iznosio 1542,705 kuna, dok pri razini rizika od 99% investitor nebi mogao izgubiti iznos veći od 2033,896.

Nakon provedene analize VaR-a za oba promatrana razdoblja zaključak je jednak kao i kod beta koeficijenta. Odnosno na temelju VaR-a ne može se odrediti koje je razdoblje rizičnije za ulaganje. Dionice Barclaysa, Burberrya, Coca Cole, Glencorea, Loyds Banka, Relxa, Rolls Roysa i Standard lifea su imali manju VaR vrijednost u razdoblju nakon Brexita, dok su ostale dionice imale manje VaR vrijednosti u razdoblju prije Brexita.

4.3. Efikasna granica u razdoblju prije Brexita

Na temelju podataka za odabrane dionice formirana je sljedeća tablica koja prikazuje cijene dionica na tjednoj razini.

Tablica 6. Cijene odabranih dionica prije Brexita

CIJENA DIONICE										
Tjedan	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
1.10.2015 - 7.10.2015	252,60	1401,40	426,39	1423,00	108,57	75,96	4166,60	1134,40	696,84	404,20
8.10.2015 - 14.10.2015	253,15	1464,00	430,13	1482,20	121,79	75,05	4413,20	1132,80	705,58	417,06
15.10.2015 - 21.10.2015	250,82	1275,80	431,30	1522,20	113,56	74,88	4511,00	1153,00	661,14	409,54
22.10.2015 - 28.10.2015	251,37	1321,40	453,26	1551,00	115,94	76,13	4571,60	1163,40	666,62	420,58
29.10.2015 - 4.11.2015	234,23	1341,60	465,11	1565,60	116,84	73,71	4348,60	1161,60	681,08	421,64
5.11.2015 - 11.11.2015	231,46	1357,60	466,68	1537,40	111,19	72,67	3983,80	1161,20	675,97	414,48
12.11.2015 - 18.11.2015	226,11	1278,40	483,29	1541,60	92,14	72,62	3952,80	1160,80	526,37	399,12
19.11.2015 - 25.11.2015	222,79	1244,80	489,51	1620,80	92,27	71,60	4020,60	1173,20	561,98	403,88
26.11.2015 - 2.12.2015	228,19	1243,20	495,61	1615,60	94,49	73,19	4112,20	1200,40	593,94	416,40
3.12.2015 - 9.12.2015	226,39	1199,40	475,77	1529,80	85,08	71,56	4177,60	1185,20	584,60	397,82
10.12.2015 - 16.12.2015	213,77	1154,60	464,85	1459,80	84,20	69,80	4095,20	1153,80	543,49	376,02
17.12.2015 - 23.12.2015	218,81	1197,80	463,29	1481,20	84,74	71,13	4092,60	1168,20	565,62	381,30
24.12.2015 - 30.12.2015	221,67	1214,67	469,90	1477,33	91,77	73,16	4223,33	1194,67	577,32	395,67
31.12.2015 - 6.1.2016	215,04	1138,50	465,85	1432,75	87,47	71,23	4242,75	1177,50	555,56	375,75
7.1.2016 - 13.1.2016	201,89	1094,40	468,09	1409,40	74,70	68,37	4319,40	1170,20	545,65	365,64
14.1.2016 - 20.1.2016	189,82	1124,20	461,89	1371,60	75,49	64,53	4334,40	1154,80	535,03	361,50
21.1.2016 - 27.1.2016	184,71	1182,60	474,10	1382,40	84,16	64,39	4658,00	1178,60	531,98	360,32
28.1.2016 - 3.2.2016	177,31	1175,40	485,45	1421,40	87,40	62,81	5003,00	1213,20	530,50	355,34
4.2.2016 - 10.2.2016	165,19	1187,60	468,12	1296,40	98,51	59,65	5635,00	1159,00	512,90	347,04
11.2.2016 - 17.2.2016	159,08	1198,60	454,33	1330,00	102,06	59,09	6088,00	1164,60	602,01	337,68
18.2.2016 - 24.2.2016	161,38	1250,00	461,59	1419,80	122,90	62,04	6419,00	1217,80	644,89	331,52
25.2.2016 - 2.3.2016	165,30	1296,20	485,83	1381,40	129,24	71,77	6385,00	1249,20	667,02	334,52
3.3.2016 - 9.3.2016	170,90	1388,20	466,84	1389,20	151,35	71,27	6390,00	1229,80	701,54	353,08
10.3.2016 - 16.3.2016	163,34	1367,00	455,78	1409,40	142,40	68,97	6262,00	1254,40	668,98	361,96
17.3.2016 - 23.3.2016	159,39	1349,20	445,95	1445,80	158,41	68,94	6505,00	1271,40	687,28	365,24
24.3.2016 - 30.3.2016	151,75	1336,33	439,50	1458,67	148,85	67,45	6306,67	1291,00	669,77	352,30
31.3.2016 - 6.4.2016	149,28	1314,40	439,05	1455,60	147,76	67,36	6307,00	1298,20	651,87	346,58
7.4.2016 - 13.4.2016	154,75	1306,40	441,52	1439,00	143,49	66,38	6712,00	1301,60	652,66	344,92
14.4.2016 - 20.4.2016	168,51	1284,40	446,94	1454,00	162,45	68,21	6610,00	1306,80	665,44	342,24
21.4.2016 - 27.4.2016	172,51	1233,20	433,22	1406,20	157,71	68,71	6408,00	1238,80	667,02	336,26
28.4.2016 - 4.5.2016	168,28	1191,50	441,29	1392,50	153,55	66,39	6432,50	1210,50	658,65	323,13
5.5.2016 - 11.5.2016	161,66	1180,40	442,71	1390,80	138,87	64,91	5975,00	1226,20	641,23	319,92
12.5.2016 - 18.5.2016	165,27	1135,40	439,38	1354,40	133,06	66,95	6241,00	1230,60	651,36	321,14
19.5.2016 - 25.5.2016	177,87	1090,40	442,29	1333,40	129,73	71,16	5968,00	1234,20	631,19	333,90
26.5.2016 - 1.6.2016	184,47	1084,33	447,77	1333,00	133,78	72,43	5796,67	1247,00	616,11	341,27

Izvor: LSE

Na temelju dionica koje su uvrštene u portfelj izračunati su tjedni prinosi koje nosi svaka od odabranih dionica te su prikazani u tablici 3.

Tablica 7. Tjedni prinosi dionica uvrštenih u portfelj

PRINOS DIONICE (%)									
Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
0,00217499	0,043700679	0,008733	0,04076	0,114866	-0,012121361	0,057499694	-0,00141	0,012451738	0,031320291
-0,0092466	-0,13759898	0,002716	0,026629	-0,06997	-0,002198065	0,021918809	0,017675	-0,0650428	-0,018195518
0,00219041	0,035118348	0,049662	0,018743	0,020741	0,016486274	0,013344395	0,00898	0,008251363	0,026600132
-0,0706224	0,015171151	0,025808	0,009369	0,007733	-0,032305752	-0,050009299	-0,00155	0,021455979	0,002517158
-0,0118965	0,011855503	0,00337	-0,01818	-0,04957	-0,014159625	-0,087617817	-0,00034	-0,00753736	-0,017127147
-0,0233855	-0,06010914	0,034973	0,002728	-0,18791	-0,0006832	-0,007811949	-0,00034	0,0214513037	-0,037762599
-0,014792	-0,02663442	0,012788	0,050099	0,00141	-0,01415105	0,017006957	0,010626	0,065448981	0,011855681
0,02394899	-0,00128617	0,012384	-0,00321	0,023753	0,021911998	0,02252702	0,02292	0,055319132	0,030528533
-0,0079194	-0,03586727	-0,04085	-0,05457	-0,1049	-0,022438949	0,015778754	-0,01274	-0,01585613	-0,045646695
-0,0573585	-0,03806747	-0,02322	-0,04684	-0,01042	-0,02491457	-0,019921363	-0,02685	-0,07291808	-0,056357308
0,0233031	0,036732577	-0,00336	0,014553	0,006417	0,018820638	-0,000635091	0,012403	0,039909526	0,013944133
0,01297098	0,01398315	0,014167	-0,00261	0,079661	0,028125908	0,031444241	0,022403	0,020480881	0,036985639
-0,0303623	-0,06475808	-0,00866	-0,03064	-0,04801	-0,026780102	0,004586938	-0,01447	-0,03842035	-0,051648077
-0,0630894	-0,03950534	0,004797	-0,01643	-0,15779	-0,040885874	0,01790486	-0,00622	-0,01799678	-0,027274786
-0,0616467	0,026865404	-0,01333	-0,02719	0,010547	-0,05785725	0,003466689	-0,01325	-0,01965844	-0,011387201
-0,0272892	0,050643733	0,026092	0,007843	0,108743	-0,002094306	0,072002979	0,0204	-0,00571483	-0,003269516
-0,0408874	-0,00610689	0,023658	0,027821	0,037798	-0,024973984	0,071451561	0,028934	-0,00277701	-0,013917448
-0,0708033	0,010325949	-0,03635	-0,09205	0,119658	-0,051534562	0,118959415	-0,0457	-0,03374814	-0,023635031
-0,0376891	0,009219745	-0,0299	0,025588	0,035343	-0,009362738	0,077322473	0,00482	0,160186393	-0,027341346
0,01435461	0,041989342	0,015853	0,065337	0,18583	0,048620573	0,052942722	0,044668	0,068807699	-0,018410562
0,02400017	0,036293356	0,051182	-0,02742	0,0503	0,145717235	-0,005310853	0,025457	0,033738862	0,009008529
0,03331659	0,068571037	-0,03987	0,005631	0,157924	-0,007050884	0,000782779	-0,01565	0,05045986	0,053997992
-0,0452447	-0,01538939	-0,02398	0,014436	-0,06096	-0,032733181	-0,020234645	0,019806	-0,04751522	0,024839048
-0,0244799	-0,01310673	-0,0218	0,025499	0,106547	-0,000460657	0,038071489	0,013461	0,026977706	0,009020963
-0,0491196	-0,00958228	-0,01457	0,00886	-0,06225	-0,021834929	-0,030963837	0,015298	-0,02580227	-0,036071586
-0,0164107	-0,01654926	-0,00102	-0,0021	-0,00735	-0,001295909	5,28527E-05	0,005562	-0,02708902	-0,016369413
0,03598717	-0,00610503	0,00561	-0,01147	-0,02932	-0,014769586	0,062236841	0,002616	0,001206273	-0,004801166
0,08518418	-0,01698358	0,012201	0,01037	0,124105	0,027284957	-0,015313315	0,003987	0,019400698	-0,007800261
0,02346011	-0,04067927	-0,03118	-0,03343	-0,02961	0,007245138	-0,031036444	-0,05344	0,002361973	-0,017627575
-0,0248557	-0,0343994	0,018451	-0,00979	-0,02673	-0,034319198	0,003816055	-0,02311	-0,01262696	-0,039845425
-0,0401042	-0,00935965	0,003218	-0,00122	-0,10049	-0,022483126	-0,073779167	0,012886	-0,02680388	-0,009968281
0,02208514	-0,03886835	-0,00755	-0,02652	-0,04274	0,030912628	0,043556328	0,003582	0,015687803	0,003806201
0,07347245	-0,04044041	0,006601	-0,01563	-0,02534	0,060954918	-0,044728563	0,002921	-0,03146815	0,038964382
0,03641583	-0,00557924	0,012306	-0,0003	0,030766	0,017643693	-0,029128823	0,010318	-0,02417437	0,021822638

Izvor: Izračun autora

Na temelju tjednih prinosa koji su prethodno izračunati dobijemo očekivani prinos te varijancu i standardnu devijaciju dionica prikazane u tablici 4.

Tablica 8. Očekivani prinosi, varijance i standardne devijacije dionica u portfelju

	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
Očekivani prinos	-0,92%	-0,75%	0,14%	-0,19%	0,61%	-0,14%	0,97%	0,28%	-0,36%	-0,50%
Varijanca σ^2	0,001501	0,001569757	0,000539	0,000919	0,007107	0,00136874	0,001915501	0,000398	0,003733123	0,000751268
Standardna devijacija	3,87%	3,96%	2,32%	3,03%	8,43%	3,70%	4,38%	2,00%	6,11%	2,74%

Izvor: Izračun autora

Iz rezultata u tablici možemo zaključiti da najveći prinos nosi dionica Randgold resources 0,97%, stoga se očekuje povećanje udjela navedene dionice u portfelju povećanjem zahtjevanog prinosa, dok najmanji prinos u portfelju nosi dionica Barclaysa.

Za formiranje optimalnog portfelja potrebno je izračunati matricu varijanci i kovarijanci. Kako bi se navedena matrica formirala potrebno je dobiti tablicu s razlikama tjednih i očekivanog prinosa koja se naziva matrica A. Matrica A prvi je korak u formiranju matrice varijanci i kovarijanci. Nakon što je navedena matrica formirana koristeći funkcijama Excela MMULT i TRANSPOSE formira se potrebna matrica varijanci i kovarijanci koja je prikazana sljedećom tablicom.

Tablica 9. Matrica varijanci i kovarijanci portfelja

Matrica varijanci i kovarijanci										
	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
Barclays	0,001501	0,000112	0,00016804	0,000183648	0,00091792	0,000979591	-0,000188175	0,0001469	0,000497124	0,000537478
Burberry	0,000112	0,00157	0,00011696	0,000210686	0,00217786	0,000244995	0,000284354	0,0001522	0,001195069	0,000514742
BT Group	0,000168	0,000117	0,00053907	0,000263119	1,7732E-06	0,000395146	-8,2128E-05	0,0002424	-0,0001754	0,000126741
Coca Cola	0,000184	0,000211	0,00026312	0,000918807	0,00068244	0,000163266	7,38293E-05	0,0004188	0,000570051	0,000286485
Glencore	0,000918	0,002178	1,7732E-06	0,000682444	0,00710676	0,000821586	0,001607018	0,000283	0,002949577	0,001006517
Lloyds Bank	0,00098	0,000245	0,00039515	0,000163266	0,00082159	0,00136874	-0,000135014	0,0003262	0,000479431	0,000396896
Randgold Resources	-0,00019	0,000284	-8,2128E-05	7,38293E-05	0,00160702	-0,000135014	0,001915501	5,574E-05	0,00071268	-2,02621E-05
Relx	0,000147	0,000152	0,00024235	0,000418788	0,00028304	0,000326202	5,57359E-05	0,0003981	0,000266565	0,000188351
Rolls Royce	0,000497	0,001195	-0,0001754	0,000570051	0,00294958	0,000479431	0,00071268	0,0002666	0,003733123	0,000578581
Standard life	0,000537	0,000515	0,00012674	0,000286485	0,00100652	0,000396896	-2,02621E-05	0,0001884	0,000578581	0,000751268

Izvor: Izračun autora

Na označenoj glavnoj dijagonali matrice nalaze se varijance prinosa odabranih dionica, na temelju kojih možemo vidjeti rižičnost pojedinih dionica. Iz dobivenih rezultata vidimo da se kao najrizičnija pokazala dionica Glencora s varijancom 0,007106.

Prethodno izračunati podaci bili su potrebni kako bi se formirao optimalan portfelj za investitora. Tablica 6 pokazuje udjele koje pojedina dionica ima u portfelju pri različitim razinama rizika.


Tablica 10. Udjeli dionica pri različitim razinama rizika

Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life	E(R _π)	σ _π
0,07103705	0,033480387	0,27412935	0	0	0	0,137633872	0,349492839	0	0,134226499	0,113%	1,50%
0	0	0,23089468	0	0	0	0,2616254	0,507479922	0	0	0,429%	1,80%
0	0	0,14017725	0	0	0	0,355563381	0,504259369	0	0	0,506%	2,00%
0	0	0,07357633	0	0	0	0,423783951	0,50263972	0	0	0,526%	2,20%
0	0	0	0	0	0	0,512143677	0,487856323	0	0	0,633%	2,50%
0	0	0	0	0	0	0,812675709	0,187324291	0	0	0,841%	3,60%
0	0	0	0	0	0	0,82508148	0,17491852	0	0	0,850%	3,65%
0	0	0	0	0	0	0,861955371	0,138044629	0	0	0,876%	3,80%
0	0	0	0	0	0	0,910433054	0,089566946	0	0	0,909%	4,00%
0	0	0	0	0	0	1	0	0	0	0,971%	4,50%

Izvor: Izračun autora

Zaključak koji možemo donijeti iz prikazane tablice je da pri nižim razinama rizika veći broj dionica je zastupljen u portfelju, dok se s povećanjem rizika kojem je izložen portfelj broj dionica koje imaju svoje udjele smanjuje sve dok portfelj nije formiran od samo jedne dionice koja je najrizičnija, no za investitora nosi najveći prinos. U odabranom portfelju to je dionica RandgoldResourcesa.

Na temelju Excelovog Solvera dobije se niz efikasnih portfelja pomoću kojih se formira efikasna granica prikazana na sljedećoj slici.



Slika13. Efikasna granica portfelja formiranog prije nastupanja Brexita

Izvor: Izradio autor

Efikasna granica prikazuje različite kombinacije koje su na izbor investitora u ovisnosti od njegovih preferencija. Odnosno ovisi o tome koliki je rizik investitor spreman preuzeti s ciljem ostvarenja profita. Optimalan portfelj za investitora je onaj koji nosi maksimalan profit uz prihvatljivu stopu rizika. Na temelju prikazane efikasne granice možemo zaključiti da očekivani prinos za investitora raste do određene razine rizika u ovom slučaju do razine rizika od 4,50% nakon čega je prinos investitora isti bez obzira na povećanje razine rizika koji je investitor spreman preuzeti.

4.4. Efikasna granica u razdoblju nakon Brexita

Daljnja analiza uključuje formiranje portfelja koji se sastoji od istih dionica kao i prethodni samo u drugom razdoblju, odnosno u razdoblju nakon što je na temelju referenduma 23.6.2016. godina izglasano da Velika Britanija napušta sastav Europske Unije.

U sljedećoj tablici prikazane su cijene dionica na tjednoj razini za razdoblje od 8 mjeseci nakon odluke o Brexitu.

Tablica 11. Cijene dionica na tjednoj razini

Cijena dionica										
Tjedan	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
1.7.2016 - 7.7.2016	135,76	1160,80	398,93	1534,20	160,42	51,15	9248,00	1403,80	707,03	276,84
8.7.2016 - 14.7.2016	145,26	1221,00	400,49	1538,40	180,95	55,04	9180,00	1411,80	730,79	279,92
15.7.2016 - 21.7.2016	150,80	1282,60	392,80	1553,60	182,28	56,00	8800,00	1399,00	737,35	287,24
22.7.2016 - 28.7.2016	149,61	1319,60	397,53	1577,20	186,42	54,13	8718,00	1417,60	741,22	292,48
29.7.2016 - 4.8.2016	149,82	1300,60	408,57	1546,40	186,69	52,81	8885,00	1426,80	765,67	301,28
5.8.2016 - 11.8.2016	159,51	1320,40	404,66	1592,00	195,66	54,69	8512,00	1444,00	770,35	333,52
12.8.2016 - 18.8.2016	161,90	1362,20	395,28	1712,00	194,97	54,24	8492,00	1456,60	786,25	354,44
19.8.2016 - 25.8.2016	163,18	1352,00	395,30	1693,60	185,19	57,20	7925,00	1449,20	781,88	354,82
26.8.2016 - 1.9.2016	169,74	1306,75	389,21	1678,75	178,30	59,22	7358,75	1443,25	765,87	360,20
2.9.2016 - 8.9.2016	172,04	1310,20	393,18	1664,20	183,65	59,03	7616,00	1461,60	766,87	364,24
9.9.2016 - 15.9.2016	171,04	1259,40	381,96	1662,40	181,44	57,24	7416,00	1423,20	719,35	341,76
16.9.2016 - 22.9.2016	168,59	1356,60	388,46	1697,80	196,70	56,84	7624,00	1451,60	727,41	348,84
23.9.2016 - 29.9.2016	167,77	1390,60	391,48	1748,40	210,94	55,18	7839,00	1455,40	710,81	344,30
30.9.2016 - 6.10.2016	170,39	1411,40	383,69	1805,60	214,79	54,74	7366,00	1476,20	742,02	353,24
7.10.2016 - 13.10.2016	170,65	1495,00	370,36	1816,60	228,11	52,82	7012,00	1459,80	763,59	346,56
14.10.2016 - 20.10.2016	174,84	1471,40	379,08	1832,00	234,26	53,92	6951,00	1455,60	762,52	330,56
21.10.2016 - 27.10.2016	184,54	1472,00	382,52	1821,80	241,11	55,77	7086,00	1449,00	743,40	338,74
28.10.2016 - 3.11.2016	187,13	1458,40	373,88	1776,80	245,90	56,48	7266,00	1440,20	722,90	338,76
4.11.2016 - 10.11.2016	189,30	1451,60	359,26	1707,80	259,44	56,98	6748,00	1371,00	736,70	345,64
11.11.2016 - 17.11.2016	209,65	1398,40	363,58	1658,60	272,70	60,37	5927,00	1309,80	735,70	355,54
18.11.2016 - 24.11.2016	212,80	1420,20	361,90	1678,00	277,43	59,52	5795,00	1364,60	663,50	348,92
25.11.2016 - 1.12.2016	215,33	1418,20	354,76	1674,80	282,50	57,96	5787,00	1371,80	674,00	345,56
2.12.2016 - 8.12.2016	226,07	1449,40	355,44	1637,40	290,71	60,06	5821,00	1339,60	663,80	358,90
9.12.2016 - 15.12.2016	228,39	1461,40	357,07	1649,20	285,24	62,56	5767,00	1378,00	667,70	363,92
16.12.2016 - 22.12.2016	226,72	1475,80	369,75	1675,80	270,62	63,71	5671,00	1414,60	678,30	363,94
23.12.2016 - 29.12.2016	224,02	1477,33	369,78	1720,67	274,35	63,38	6123,33	1442,00	681,67	367,73
30.12.2016 - 5.1.2017	230,73	1479,00	375,83	1773,50	284,11	64,14	6487,50	1441,25	661,25	373,08
6.1.2017 - 12.1.2017	234,40	1528,60	389,41	1791,00	303,37	66,01	6648,00	1451,60	665,20	358,72
13.1.2017 - 19.1.2017	230,77	1631,20	384,47	1799,80	317,54	65,22	6742,00	1444,60	683,40	353,16
20.1.2017 - 26.1.2017	228,75	1657,80	335,43	1814,40	322,62	65,08	6686,00	1413,20	687,70	349,74
27.1.2017 - 2.2.2017	223,38	1638,20	304,59	1806,60	325,40	65,20	6680,00	1421,80	671,10	348,02
3.2.2017 - 9.2.2017	227,36	1623,00	308,47	1805,00	312,49	65,95	7280,00	1453,20	698,00	356,96
10.2.2017 - 16.2.2017	234,70	1637,00	307,78	1840,00	325,43	66,54	7404,00	1468,40	716,20	368,08
17.2.2017 - 23.2.2017	234,93	1662,40	323,73	1966,60	326,34	68,05	7438,00	1483,00	724,40	373,84
24.2.2017 - 1.3.2017	225,80	1684,00	330,27	1940,33	325,08	69,05	7596,67	1500,33	772,83	367,53

Izvor: LSE

Na temelju prethodnih podataka dobiveni su očekivani prinosi za pojedinu dionicu koji su prikazani u tablici 8., te su potrebni za izračun sljedećih podataka na temelju kojih će se formirati efikasna granica portfelja.

Tablica 12. Tjedni prinosi dionica u portfelju

Prinos dionice(%)									
Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
0,067636619	0,050560773	0,003903	0,002734	0,120425	0,073370373	-0,007380107	0,005682641	0,033048289	0,011064126
0,037429215	0,049219073	-0,01939	0,009832	0,007323	0,017147394	-0,042275483	-0,00910779	0,008937094	0,025814255
-0,007922547	0,028439393	0,01197	0,015076	0,022458	-0,033817805	-0,009361868	0,013207605	0,005243709	0,018078185
0,001402665	-0,014502964	0,027393	-0,01972	0,001447	-0,024686147	0,018974608	0,006468874	0,032456675	0,029643777
0,062672043	0,015109025	-0,00962	0,029061	0,046929	0,03490457	-0,042887529	0,011982866	0,00608298	0,101662769
0,014872244	0,031166319	-0,02345	0,072671	-0,00353	-0,008262234	-0,002352389	0,008687912	0,020434938	0,060836246
0,007875025	-0,007516062	5,06E-05	-0,01081	-0,05146	0,053170219	-0,069102224	-0,005093273	-0,005578108	0,001071539
0,03939924	-0,034041839	-0,01552	-0,00881	-0,03791	0,034586025	-0,074132238	-0,004114165	-0,020680205	0,015048814
0,013473882	0,002636659	0,010142	-0,0087	0,029564	-0,003095218	0,034361216	0,012634211	0,001297017	0,011153558
-0,005829561	-0,03954438	-0,02895	-0,00108	-0,01211	-0,030756836	-0,026611469	-0,026623869	-0,06395973	-0,063704255
-0,014427715	0,074346152	0,016874	0,021071	0,080755	-0,00708253	0,027661338	0,019758539	0,011130311	0,020504628
-0,004875738	0,024753739	0,007744	0,029368	0,069894	-0,02967598	0,027810109	0,002614381	-0,02308486	-0,013099994
0,015495933	0,014846811	-0,0201	0,032192	0,018087	-0,007896549	-0,062236457	0,014190441	0,042973224	0,025634342
0,001524748	0,057544087	-0,03536	0,006074	0,060167	-0,035853599	-0,049251851	-0,011171778	0,028654499	-0,019091749
0,024256595	-0,015911878	0,023272	0,008442	0,026604	0,020761473	-0,008737433	-0,002881253	-0,001399672	-0,047267778
0,053994972	0,000407692	0,009034	-0,00558	0,028822	0,03362458	0,019235472	-0,004544523	-0,025393083	0,024444666
0,01393732	-0,009282076	-0,02285	-0,02501	0,019672	0,012757184	0,025084927	-0,006091671	-0,027963358	5,90406E-05
0,011529496	-0,004673548	-0,03989	-0,03961	0,053601	0,008778016	-0,073959769	-0,049241592	0,018909854	0,020105879
0,102106415	-0,03733767	0,011953	-0,02923	0,049847	0,057789993	-0,129727982	-0,045665947	-0,001358327	0,02823999
0,014913284	0,015468981	-0,00463	0,011629	0,017196	-0,014145829	-0,022522706	0,040986892	-0,103293573	-0,018795091
0,011818978	-0,001409245	-0,01993	-0,00191	0,01811	-0,026626475	-0,001381454	0,005262401	0,015701257	-0,00967638
0,048672951	0,021761216	0,001915	-0,02258	0,028648	0,035657543	0,005858046	-0,023752684	-0,015249212	0,037877509
0,010210008	0,008245203	0,004575	0,007181	-0,019	0,040715436	-0,009320054	0,028262111	0,005858072	0,013890265
-0,007338918	0,009805335	0,034895	0,016	-0,05262	0,01821544	-0,016786546	0,026213633	0,015750697	5,49556E-05
-0,011995322	0,001038445	9,01E-05	0,026421	0,013689	-0,005245776	0,076741142	0,019184233	0,004951112	0,010369019
0,029506071	0,001127523	0,016206	0,030243	0,034966	0,011933456	0,057770638	-0,000520246	-0,030408797	0,014421434
0,015802533	0,0329861	0,035509	0,009819	0,065583	0,028837624	0,024438809	0,007155604	0,005955764	-0,039237332
-0,015607514	0,064963656	-0,01277	0,004901	0,045651	-0,012070005	0,014040559	-0,00483393	0,026992592	-0,015620928
-0,008791839	0,016175482	-0,13645	0,008079	0,015871	-0,002241018	-0,008340829	-0,02197583	0,006272357	-0,009731191
-0,023755347	-0,011893344	-0,09645	-0,00431	0,00858	0,001964999	-0,0008978	0,006067038	-0,024434539	-0,004930072
0,017660307	-0,00932179	0,012658	-0,00089	-0,04048	0,011406388	0,086012875	0,021844347	0,039300946	0,025363781
0,031773439	0,00858901	-0,00224	0,019205	0,040575	0,008876066	0,016889533	0,010405351	0,025740355	0,030676575
0,000979495	0,015397043	0,050525	0,066541	0,002792	0,022380676	0,004581601	0,009893691	0,011384268	0,015527593
-0,039637946	0,012909574	0,019991	-0,01345	-0,00386	0,014646933	0,021107559	0,011620242	0,064719689	-0,017013881

Izvor: Izračun autora

Na temelju dobivenih prinosa formira se tablica s očekivanim prinosima, varijancama i standardnim devijacijama na temelju kojih možemo utvrditi očekivane prinose i rizike dionica.

Tablica 13. Očekivani prinosi, varijance i standardne devijacije odabranih dionica

	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
Očekivani prinos	1,50%	1,09%	-0,56%	0,69%	2,08%	0,88%	-0,58%	0,20%	0,26%	0,83%
Varijanca	0,000796167	0,000720491	0,001215415	0,000552283	0,001363262	0,000726993	0,00192712	0,000357945	0,000954258	0,000886293
Standardna devijacija	2,82%	2,68%	3,49%	2,35%	3,69%	2,70%	4,39%	1,89%	3,09%	2,98%

Izvor: Izračun autora

Dobiveni rezultati pokazuju da je najrizičnija dionica Randgold resourcesa sa standardnom devijacijom 4,39%, dok se najveći prinos očekuje od dionice Glencora što je značajna promjena u odnosu na stanje prije Brexita.

Kako bi se formirala efikasna granica potrebno je prethodno formirati matricu varijanci i kovarijanci koja je prikazana sljedećom tablicom.

Tablica 14. Matrica varijanci i kovarijanci

Matrica varijanci i kovarijanci										
	Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life
Barclays	0,000796	-0,00015	0,000165	-0,000108515	0,000288757	0,000480847	-0,000496281	-0,000173481	-0,000104372	0,000383164
Burberry	-0,00015	0,00072	3,98E-05	0,000240647	0,00050523	-0,000111179	0,000225784	0,00013377	0,000265556	7,93135E-05
BT Group	0,000165	3,98E-05	0,001215	0,000123299	5,92625E-06	0,000210527	0,000334888	0,000231523	0,000137795	7,30342E-05
Coca Cola	-0,00011	0,000241	0,000123	0,000552283	7,35454E-06	-0,000131045	0,000255634	0,000220311	4,44324E-05	0,000143537
Glencore	0,000289	0,000505	5,93E-06	7,35454E-06	0,001363262	4,29685E-06	5,89165E-05	-0,000140354	8,10526E-05	2,68733E-05
Lloyds Bank	0,000481	-0,00011	0,000211	-0,000131045	4,29685E-06	0,000726993	-0,000310285	-7,34277E-05	6,45755E-05	0,000224158
Randgold Resources	-0,0005	0,000226	0,000335	0,000255634	5,89165E-05	-0,000310285	0,00192712	0,000409669	9,5392E-05	-0,000117546
Relx	-0,00017	0,000134	0,000232	0,000220311	-0,000140354	-7,34277E-05	0,000409669	0,000357945	2,00619E-05	4,66387E-05
Rolls Royce	-0,0001	0,000266	0,000138	4,44324E-05	8,10526E-05	6,45755E-05	9,5392E-05	2,00619E-05	0,000954258	0,000252613
Standard life	0,000383	7,93E-05	7,3E-05	0,000143537	2,68733E-05	0,000224158	-0,000117546	4,66387E-05	0,000252613	0,000886293

Izvor: Izračun autora

Korištenjem Solvera u Excelu dobivena je tablica koja prikazuje udjele dionica u portfelju pri različitim razinama rizika.


Tablica 15. Udjeli dionica u portfelju pri različitim razinama rizika

Barclays	Burberry	BT Group	Coca Cola	Glencore	Lloyds Bank	Randgold Resources	Relx	Rolls Royce	Standard life	E(R _π)	σ _π
0,325215554	0,143170895	0	0,175644682	0,183920975	0,06092461	0	0,111123	0	0	1,220%	1,50%
0,396614059	0,159769197	0	0,185806268	0,244125829	0,013684648	0	0	0	0	1,420%	1,80%
0,414482159	0,132553373	0	0,132418094	0,320546374	0	0	0	0	0	1,520%	2,00%
0,419073877	0,091613788	0	0,091783284	0,39752905	0	0	0	0	0	1,620%	2,20%
0,426330224	0,044913911	0	0,029223167	0,499532698	0	0	0	0	0	1,750%	2,50%
0,429276858	0,002371925	0	0	0,568351216	0	0	0	0	0	1,830%	2,70%
0,268753271	0	0	0	0,731246729	0	0	0	0	0	1,920%	3,00%
0,182350297	0	0	0	0,817649703	0	0	0	0	0	1,970%	3,20%
0,032055406	0	0	0	0,967944594	0	0	0	0	0	2,060%	3,60%
0	0	0	0	1	0	0	0	0	0	2,080%	3,65%

Izvor: Izračun autora

Broj dionica koje su uvrštene u portfelj znatno je veći pri manjim razinama rizika, kako se povećava rizik kojeg preuzima investitor na tržištu tako je sve manji broj dionica zastupljen u portfelju sve dok se portfelj ne sastoji samo od jedne dionice koja investitoru nosi najveći prinos.

Na temelju prethodne tablice formirana je efikasna granica koja prikazuje sve efikasne portfelje za investitora. Prinos za investitora raste do određene točke rizika nakon čega je prinos koji portfelj nosi jednak bez obzira na razinu rizika koju je investitor spreman preuzeti. Maksimalan prinos u ovom slučaju postiže se pri razini rizika od 3,65%.




Slika14. Efikasna granica portfelja formiranog nakon odluke o Brexitu

Izvor: Izradio autor

4.5. Usporedba dobivenih rezultata

Izlazak Velike Britanije iz Europske Unije doveo je do velike zabrinutosti, kako stanovnika Velike Britanije protivnika Brexita tako i ostatka svijeta. Pretpostavka je bila nagli pad britanskog tržišta kapitala uz značajno povećanje rizika te pad prinosa za investitore. Nakon što se tržište stabiliziralo, predviđanja mnogih analitičara su se pokazala krivima. Što je dokazano u ovom radu provedenom analizom. Slika prikazuje efikasne granice portfelja formiranih od istih dionica u dva različita razdoblja. Prije i poslije Brexita.



Slika 15. Usporedba formiranih portfelja

Izvor: Izradio autor

Iz prikazane slike možemo vidjeti da efikasna granica portfelja koji je formiran za vremensko razdoblje nakon Brexita nosi investitoru značajno veće prinose od portfelja za koji se pretpostavljalo da će biti isplativiji investitoru. Ukoliko usporedimo prinose pojedinih portfelja pri istoj razini rizika od 2% vidimo da portfelj za razdoblje prije Brexita nosi prinos od 0,506% dok portfelj formiran u razdoblju nakon Brexita nosi prinos od 1,520% . Navedeno predstavlja značajan porast prinosa za investitora.

ZAKLJUČAK

Moderna teorija portfelja je jedna od najpoznatijih teorija pronalaženja optimalnog portfelja vrijednosnih papira čije temelje postavlja Harry Max Markowitz 1952. godine. Tim modelom možemo, uz pretpostavku da imamo sve potrebne informacije, formirati portfelj koji na određenom stupnju rizika donosi najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalni rizik⁴⁹. Prema Markowitzevom modelu rizik koji nosi portfelj može se reducirati diversifikacijom. Diversifikacija portfelja odnosno formiranje portfelja kombinirajući vrijednosnice iz različitih sektora umanjit će vjerojatnost nastupa gubitka.

Londonska burza stara je 300 godina te je jedna od najstarijih burzi. Najznačajnija je europska burza te jedna od najznačajnijih svjetskih burza koja pruža velike mogućnosti ulaganja i trgovanja, a ondje kotiraju dionice više od 2.900 kompanija iz više od 60 zemalja diljem svijeta. Kao takva predstavlja jednu od najstabilnijih burza na svijetu. 2016. godina dokaz je da se i najstabilnija svjetska tržišta ne mogu oduprijeti utjecajima tržišnih rizika. Izlazak Velike Britanije iz Europske Unije na temelju referenduma doveo je do značajnih nestabilnosti ne samo britanskog tržišta kapitala, nego i svih svjetskih tržišta.

Na početku rada postavljene su tri hipoteze koje bi na temelju provedenog istraživanja trebale biti prihvaćene ili odbačene.

U radu su promatrani prinosi i rizici deset dionica, jedan formiran za razdoblje prije odluke Velike Britanije o napuštanju Europske Unije te drugi formiran nakon rezultata provedenog referenduma 23.6.2016. godine. Kako bi se dobili rezultati na temelju kojih bi se dokazao utjecaj Brexita na britansko tržište kapitala.

Na temelju provedene analize odbacuje se prva hipoteza da prinos koji portfelj nosi investitoru uz zadanu stopu rizika značajno opada nakon Brexita. Prinosi portfelja formiranog za razdoblje nakon Brexita značajno su bolji za investitora od prinosa koji bi investitor ostvario na temelju portfelja formiranog za razdoblje prije Brexita

⁴⁹Jerončić M., Aljinović Z. (2011): "Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija", Stručni članak, Ekonomski pregled 62 (9-10), str. 585

Na temelju provedene analize beta koeficijenta i VaR-a za oba promatrana razdoblja ne može se donijeti zaključak da je portfelj u jednom razdoblju rizičniji nego u drugom. Dionice Barclaysa, Coca-Cole, Glencora, Lloyds Banka te RollsRoyca imaju manji beta koeficijent u razdoblju nakon Brexita, dok ostale dionice bolji rezultat beta koeficijenta imaju u razdoblju prije Brexita. Nakon provedene analize VaR-a za oba promatrana razdoblja zaključak je jednak kao i kod beta koeficijenta. Odnosno na temelju VaR-a ne može se odrediti koje je razdoblje rizičnije za ulagače.

Posljednja postavljena hipoteza je da nestabilnost na britanskom tržištu kapitala negativno je utjecala na sva europska i svjetska tržišta. Postavljena hipoteza se prihvaća na temelju istraživanja rezultata analitičara. Neočekivani rezultati referenduma kojim je izglasan izlazak Velike Britanije iz EU iznenadio je cijeli svijet. Posljedice referenduma snažno su utjecale na europsko gospodarstvo i financijsku industriju. Financijski sektor je posebno ugrožen zbog velike koncentracije financijskih usluga u Britaniji i činjenice da se gotovo 80% svih financijskih transakcija EU inicira u toj zemlji.

Konačan zaključak provedene analize je da je Brexit doveo do kratkoročnog pada vrijednosti indexa te negativnog reagiranja tržišta zbog straha. No, na kraju promatranog razdoblja od 8 mjeseci nakon Brexita možemo ustanoviti da su početni šok i predviđanja analitičara bili pogrešni, te da su konačni rezultati u globalu neočekivano pozitivni za britansko tržište. Prinosi su porasli, rizici se smanjili, povećao se izvoz, dok je Europska Unija izgubila jednu od najvećih sila svijeta.

SAŽETAK

Ključne riječi: Moderna teorija portfelja, dionice, londonska burze, Brexit, rizik

Cilj provedenog istraživanja je bilo formiranje i usporedba dioničkih portfelja formiranih na britanskom tržištu kapitala u razdoblju prije i nakon nastupanja Brexita koristeći se modernom teorijom portfelja za dobivanje željenih rezultata. Korišteno je deset istih dionica uvrštenih u indeks FTSE 100 te je na temelju analize formiranih portfelja napravljena usporedba istih. Cilj je bio dokazati da je prinos dioničkog portfelja formiranog prije Brexita veći od identičnog dioničkog portfelja formiranog nakon odluke o Brexitu.

Također cilj analize je bilo i utvrđivanje razine rizika u oba formirana portfelja na temelju beta koeficijenta i VaR-a kako bi se dokazalo da protfelj formiran za razdoblje nakon Brexita nosi veći rizik za investitora. Što je provedenom analizom odbačeno.

U radu je također analiziran i dokazan negativan utjecaj koji je napuštanje Europske Unije od strane Velike Britanije imalo na ostatak Europe i Svijeta.

SUMMARY

Key words: Modern portfolio theory, stocks, London stock exchange, Brexit, risk

The aim of the study was the establishment and comparison of equity portfolio formed on the British capital market in the period before and after the Brexit decision using modern portfolio theory to obtain the desired results. Same ten stocks have been used, all part of FTSE 100 index and based on the analysis of the established portfolio comparison of the same has been made. The goal was to prove that the yield of the portfolio formed before Brexit is better than the identical portfolio formed after the Brexit decision.

The research target was also to determine the level of risk in both portfolios. Risk was to be determined using beta and VaR to prove that the portfolio formed for the period after Brexit carries higher risk for the investor. What was rejected after analysis.

This paper analysed and proved negative impact that United Kingdom leaving the European Union had on the rest of Europe and the World itself.

LITERATURA:

1. Aljinović, Z., Marasović, B., Tomić-Plazibat, N., (2005): „An Application of MATLAB and Excel in Financial Modeling“, Proceedings of the 28th International Convention MIPRO 2005, Conference "Computers in Education", Rijeka : Studio Hofbauer, str. 120-125.
2. Aljinović Z., Marasović B., Tomić-Plazibat, N., (2005): „The selection of the optimal portfolio on the Croatian capital market“, Proceedings of the Sixth International Conference "Enterprise in Transition", Split : Ekonomski fakultet Split, str. 299-301(Ex. abstract), Full text on CD ROM
3. Aljinović Z., Marasović B., Šego B. (2011): " Financijsko modeliranje", Split: Sveučilište u Splitu, Ekonomski fakultet Split
4. Aljinović Z., Marasović B. (2012): Matematički modeli u analizi razvoja hrvatskog financijskog tržišta", Split: Sveučilište u Splitu, Ekonomski fakultet Split
5. Benić V., Franić I. (2008): "Komparativna analiza likvidnosti tržišta kapitala hrvatske i zemalja regije", Financijska teorija i praksa 32 (4) str. 480-500
6. Benninga, S., (2000): „Financial Modeling“, The MIT Press, Cambridge.
7. Dhingra S., Ottaviano G., Sampson T., Van Reenen J. (2016): "The consequences of Brexit for UK trade and living standards", Centre for economic performance, London School of Economics and Political Science, str. 1-15 raspoloživo na: http://eprints.lse.ac.uk/66144/1/_lse.ac.uk_storage_LIBRARY_Secondary_libfile_shared_repository_Content_LSE%20BrexitVote%20blog_brexit02.pdf
8. Golem S. (2015): "Metodologije ekonomskih istraživanja", nastavni materijali, Sveučilište Splitu, Ekonomski fakultet Split
9. Jakšić S. (2007): "Primjena Markowitzove teorije na tržište dionica Zagrebačke burze", Zbornik Ekonomskog fakulteta u Zagrebu godina 5, str 332-343
10. Kunovac D. (2010): " Asimetrične korelacije na tržištu kapitala u Hrvatskoj", Odabrani prijevodi br.7/11, Institut za javne financije, str. 2-6, 21-22, raspoloživo na: <http://www.ijf.hr/OP/7.pdf>

11. Marasović, B., T. Poklepović, Z. Aljinović (2011): „Markowitz' Model with Fundamental and Technical Analysis-Complementary methods or Not“, Croatian Operational Research Review (CRORR), Vol 2, pp. 122-132
12. Marasović, B., S. Pivac, S. V. Vukasović (2015): „The Impact of Transaction Costs on Rebalancing an Investment Portfolio in Portfolio Optimization“, International Journal of Social Education Economics and Management Engineering, Vol 13 No 3
13. Milovanović-Morić B., Ćurković M. (2014): "Utjecaj svjetske financijske krize na formiranje multisektorski-diverzificiranih optimalnih portfelja uz pomoć Markowitzove teorije na zagrebačkoj burzi", Ekonomska misao i praksa br. 1, str. 390-392
14. Orsag S. (2011): " Vrijednosni papiri- Investicije i instrumenti financiranja", Sarajevo: Revicon d.o.o., str. iiv-x, 1-5, raspoloživo na: <http://bs.scribd.com/doc/40328793/Vrijednosni-Papiri-Silvije-Orsag#scribd>
15. Orsag S.,Dedi L.,(2014):"Tržište kapitala", Zagreb:Alka script
16. Tkalac Verčić A., Sinčić Ćorić D., Pološki Vokić N. (2010): " Priručnik za metodologiju istraživačkog rada: kako osmisлити, provesti i opisati znanstveno i stručno istraživanje", Zagreb:M.E.P., raspoloživo na: <http://www.manager.hr/adminmax/images/upload/AKCIJE/metodologija.pdf>
17. Žugaj M., Dumičić K. i Dušak V. (2006): "Temelji Znanstvenoistraživačkog rada: Metodologija i metodika", Varaždin: Tiva
18. Tomić-Plazibat, N., Aljinović, Z., Marasović, B., (2006): "Matematički modeli u financijskom upravljanju". Split: Sveučilište u Splitu, Ekonomski fakultet Split

Internetski izvori:

1. <http://www.poslovnipuls.com/2016/06/28/post-brexit-neizvjesnost-neizdrziva-za-britansko-gospodarstvo-i-financije/> online 11.9.2016
2. <https://www.theguardian.com/business/2016/jul/08/brexit-fallout-the-economic-impact-in-six-key-charts> online 10.9.2016.
3. www.wikipedia.org online 12.9.2016.
4. <http://www.londonstockexchange.com/home/homepage.htm> online 11.9.2016.
5. <http://web.efzg.hr/dok/mat/pposedel/Moderna%20teorija%20portfelja.pdf> online 12.9.2016.
6. <http://www.bbc.com> 25.2.2017.
7. <http://www.ftse.com/products/indices/uk> 1.3.2017.

POPIS SLIKA

Slika 1. Funkcija korisnosti investitora koji izbjegava rizik

Slika 2. Funkcija korisnosti investitora koji izbjegava rizik, investitora koje je indiferentan u odnosu na rizik i investitora koji je sklon riziku

Slika 3. Skup mogućih portfelja

Slika 4. (a) skup minimalne varijance (b) efikasna granica

Slika 5. Primjer efikasnog i neefikasnog portfelja

Slika 6. Sistemski i nesistemski rizik u odnosu na ukupni rizik

Slika 7. Metoda rizične vrijednosti

Slika 8. Metode izračuna rizične vrijednosti

Slika 9: Struktura tržišta kapitala

Slika 10. Rezultati Brexita

Slika 11. Rezultati Brexita po dobnim skupinama

Slika 12. Utjecaj Brexita na životne standardne drugih zemalja

Slika13. Efikasna granica portfelja formiranog prije nastupanja Brexita

Slika14. Efikasna granica portfelja formiranog nakon odluke o Brexitu

Slika15. Usporedba formiranih portfelja

POPIS TABLICA

Tablica 1. Odabrane dionice sa Londonske burze vrijednosnih papira

Tablica 2. Beta koeficijent za portfelj prije Brexita

Tablica 3. Beta koeficijent za portfelj poslije Brexita

Tablica 4. VaR portfelja prije Brexita pri razini vjerovatnosti 95% i 99%

Tablica 5. VaR portfelja poslije Brexita pri razini vjerovatnosti 95% i 99%

Tablica 6. Cijene odabranih dionica prije Brexita

Tablica 7. Tjedni prinosi dionica uvrštenih u portfelj

Tablica 8. Očekivani μ , varijance i standardne devijacije dionica u portfelju

Tablica 9. Matrica varijanci i kovarijanci portfelja

Tablica 10. Udjeli dionica pri različitim razinama rizika

Tablica 11. Cijene dionica na tjednoj razini

Tablica 12. Tjedni prinosi dionica u portfelju

Tablica 13. Očekivani prinosi, varijance i standardne devijacije odabranih dionica

Tablica 14. Matrica varijanci i kovarijanci

Tablica 15. Udjeli dionica u portfelju pri različitim razinama rizika